

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

WAGNER MARTINS DE SOUZA

**CLASSIFICADOR *RANDOM FOREST*
PARA ELETROMIOGRAFIA DE
SUPERFÍCIE: UMA ABORDAGEM EM
FPGA**

Porto Alegre
2023

WAGNER MARTINS DE SOUZA

**CLASSIFICADOR *RANDOM FOREST*
PARA ELETROMIOGRAFIA DE
SUPERFÍCIE: UMA ABORDAGEM EM
FPGA**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Eletrônica

ORIENTADOR: Prof. Dr. ALEXANDRE BALBINOT

CO-ORIENTADOR: Prof. Dr. TIAGO OLIVEIRA WEBER

Porto Alegre

2023

WAGNER MARTINS DE SOUZA

**CLASSIFICADOR *RANDOM FOREST*
PARA ELETROMIOGRAFIA DE
SUPERFÍCIE: UMA ABORDAGEM EM
FPGA**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: _____

Prof. Dr. ALEXANDRE BALBINOT, UFRGS

Doutor pela Universidade Federal do Rio Grande do Sul –
Porto Alegre, Brasil

Banca Examinadora:

Prof. Dr. FRANCISCO JOSÉ FRAGA DA SILVA, UFABC

Doutor pelo Instituto Tecnológico da Aeronáutica – São José dos Campos, Brasil

Prof. Dr. JULIANO COSTA MACHADO, IFSUL

Doutor pela Universidade Federal do Rio Grande do Sul – Porto Alegre, Brasil

Prof. Dr. VALNER JOÃO BRUSAMARELLO, UFRGS

Doutor pela Universidade Federal de Santa Catarina – Florianópolis, Brasil

Coordenador do PPGEE: _____

Prof. Dr. Jeferson Vieira Flores

Porto Alegre, agosto de 2023.

DEDICATÓRIA

Dedico este trabalho aos meus pais, sem os quais nada seria possível.

AGRADECIMENTOS

Ao Programa de Pós-Graduação em Engenharia Elétrica e seu corpo docente, pela oportunidade de cursar um ensino de qualidade.

Aos professores Alexandre Balbinot e Tiago Weber pela orientação, fornecendo auxílio e diretrizes de modo a viabilizar esta dissertação.

À empresa AEL Sistemas por ceder a infraestrutura dos laboratórios para que fossem realizados os testes de validação do projeto.

Aos colegas de laboratório pela prontidão e entusiasmo em poder auxiliar.

À minha família, que foi o pilar de sustentação deste importante passo.

À Deus e meus guias, pela força e serenidade nos momentos mais conturbados.

RESUMO

Nas últimas décadas o estudo dos sinais mioelétricos foram amplamente difundidos com o intuito de melhorar a capacidade motora ou de diagnosticar distúrbios ligados ao movimento humano. Diferentes técnicas de aprendizado de máquina foram desenvolvidas com o intuito de auxiliar no controle de próteses através da predição do movimento realizado. Na literatura são encontrados trabalhos com taxa de acerto superior a 90% em alguns cenários pré determinados em ensaios conduzidos em *setup* de laboratório. Com o objetivo de flexibilizar o processo de aquisição e treinamento dos sistemas classificatórios, este trabalho propõe o desenvolvimento de um protótipo de um classificador *Random Forest* sistema embarcado em FPGA capaz de adquirir, processar e classificar movimentos localmente sem a necessidade de um ambiente de laboratório. A motivação desta abordagem se deve ao fato de não haver na literatura especializada uma grande abordagem dedicada ao uso de sistemas embarcados além de avaliar o efeito do paralelismo em sistemas de aquisição multicanais. O modelo inteligente proposto apresentou uma taxa de acerto de 83% na classificação da base Flor de Iris e de 81% quando classificando os sinais de sEMG do repositório NinaPRO. Quando submetido a aquisição de dados experimentais, o modelo apresentou uma taxa de 73,8% de acerto nos movimentos propostos. Estas taxas estão abaixo dos resultados encontrados na literatura clássica, porém estes resultados foram obtidos computacionalmente em que a quantidade de recursos de hardware disponíveis para processamento são abundantes enquanto que neste trabalho uma grande quantidade de recursos da FPGA foram utilizados totalizando 95,6% das LUTs disponíveis e 79,4% da memória RAM disponível no sistema.

Palavras-chave: FPGA, Classificador, Eletromiografia de superfície, *Random Forest*.

ABSTRACT

In recent decades, the study of myoelectric signals has been widely disseminated with the aim of improving motor capacity or diagnosing disorders related to human movement. Different machine learning techniques have been developed with the aim of helping to control prostheses by predicting the movement performed. In the literature, studies are found with a hit rate greater than 90% in some predetermined scenarios in tests conducted in laboratory setup. With the objective of making the process of acquisition and training of classification systems more flexible, this work proposes the development of a prototype of a classifier Random Forest embedded system in FPGA able to acquire, process and classify movements locally without the need of a controlled environment. The motivation for this approach is due to the fact that in the specialized literature there is not a large approach dedicated to the use of embedded systems in addition to evaluating the effect of parallelism in multichannel acquisition systems. The proposed intelligent model presented a hit rate of 83% in the classification of the Iris dataset and of 81% when classifying the sEMG signals from the NinaPRO repository. When submitted to the acquisition of experimental data, the model presented a rate of 73.8% of success in the proposed movements. These rates are below the results found in the classical literature, but these results were obtained computationally in which the amount of hardware resources available for processing are abundant while in this work a large amount of FPGA resources were used, totaling 95.6% of the Available LUTs and 79.4% of available RAM on the system.

Keywords: Random Forest, Classifier, Surface Electromyography, FPGA.

SUMÁRIO

LISTA DE ILUSTRAÇÕES	9
LISTA DE TABELAS	12
LISTA DE ABREVIATURAS	13
1 INTRODUÇÃO	14
2 CONCEITOS TEÓRICOS	16
2.1 CONCEITOS SOBRE ELETROMIOGRAFIA	16
2.2 ASPECTOS GERAIS SOBRE PROCESSAMENTO E MODELOS INTELIGENTES EM sEMG	19
2.2.1 Extração de Características	19
2.2.2 Classificadores	21
2.2.2.1 Árvores de Decisão	21
2.2.2.2 Random Forests	23
2.2.3 Sistemas Embarcados	26
3 METODOLOGIA EXPERIMENTAL	28
3.1 ETAPA DE AQUISIÇÃO E CONDICIONAMENTO	30
3.2 ETAPA DE PROCESSAMENTO	34
3.2.1 Extração de características em VHDL	36
3.2.2 Classificador <i>Random Forest</i> em VHDL	40
3.3 PROCEDIMENTO PARA VALIDAÇÃO DO CIRCUITO DE AQUISIÇÃO	45
3.3.1 Autonomia do sistema	46
3.3.2 Relação sinal/ruído	47
3.3.3 Validação dos filtros	48
3.4 PROCEDIMENTO PARA VALIDAÇÃO DO CLASSIFICADOR	49

3.4.1	Avaliação do desempenho do sistema	49
3.4.2	Protocolo experimental para validação do sistema completo	52
4	RESULTADOS & DISCUSSÃO	56
4.1	VALIDAÇÃO DO CIRCUITO DE AQUISIÇÃO	56
4.2	VALIDAÇÃO DO CLASSIFICADOR	59
4.2.1	Análise do indivíduo com pior desempenho	61
4.2.2	Análise da aquisição experimental de sinais sEMG	63
4.3	CONSUMO DE RECURSOS	65
4.4	COMPARAÇÕES COM OUTROS TRABALHOS NA ÁREA	67
5	CONCLUSÕES	69
	REFERÊNCIAS BIBLIOGRÁFICAS	71
	APÊNDICE A	76
A.1	Layout da placa	76
A.2	Matriz de confusão dos demais usuários da base NinaPRO	77
A.3	Varredura em frequência dos demais canais	79

LISTA DE ILUSTRAÇÕES

1	Representação básica do sistema motor humano.	17
2	Resposta elétrica da unidade motora durante o movimento.	18
3	Exemplo de um sinal de EMG.	19
4	Exemplo de uma árvore de decisão utilizado como classificador em um sistema de empréstimos.	22
5	Fluxograma de criação de <i>Random Forests</i>	25
6	Processo de execução de uma <i>Random Forest</i>	26
7	Diagrama de blocos do sistema proposto neste trabalho.	28
8	Representação 3D do protótipo proposto.	29
9	Protótipo implementado.	30
10	Circuito com ganho ajustável utilizado neste trabalho.	31
11	Filtro ativo passa altas <i>Butterworth</i> de segunda ordem com frequência de corte de 5Hz.	32
12	Filtro passa baixas <i>Butterworth</i> de segunda ordem com frequência de corte de 500Hz.	33
13	Diagrama de blocos simplificado do ADS1198.	33
14	Kit de desenvolvimento da PISWORDS.	35
15	Fluxograma de operação da etapa de controle.	36
16	Fluxograma de calibração do sistema proposto.	37
17	Janela retangular deslizante para a extração de características do sinal de eletromiografia.	38
18	Diagrama de blocos para extração da característica "Potência".	40
19	Diagrama de blocos para extração do valor médio absoluto (MAV).	41
20	Diagrama de blocos para extração das características: (a) Valor RMS. (b) Comprimento de onda (WL).	42
21	Mapa de memória para alocação das características calculadas.	43
22	Representação da arquitetura de uma <i>Random Forest</i>	43
23	Representação da descrição de hardware de uma árvore de decisão.	44

24	Estrutura de uma árvore que compõem a <i>Random Forest</i>	45
25	Estrutura da ramificação das árvores de decisão.	45
26	Procedimento experimental para validação do circuito de aquisição. . .	46
27	Circuito de alimentação do protótipo desenvolvido. (a) Conector mini-USB para entrada de alimentação - (b) Circuito carregador de bateria (c) Saídas de 3V3 - (d) Capacitores de desacoplamento.	47
28	Diagrama esquemático de um canal de aquisição.	48
29	Esquemático para varredura em frequência para validação dos filtros ativos.	48
30	Varredura realizada entre as frequências de passagem e corte para validação dos filtros ativos.	49
31	Configuração do sistema utilizada para validar o classificador embar- cado.	51
32	Movimentos realizados pelo indivíduo durante o protocolo experi- mental.	51
33	Musculatura do segmento mão-braço do corpo humano.	52
34	Preparação para o protocolo experimental de ensaios.	53
35	Procedimento experimental para coleta de dados.	54
36	Rotina de calibração para determinação da posição de repouso do sistema proposto.	54
37	Execução do protocolo experimental de ensaios.	55
38	Curva V x t os circuitos: Vbat em azul; +3V3 em laranja.	56
39	Medição realizada para determinação da SNR do canal 1.	57
40	Resposta em frequência do conjunto de filtros utilizados no canal 1. . .	58
41	Resposta em frequência do conjunto de filtros utilizados no canal 2. . .	58
42	Taxa de acerto do conjunto de teste do classificador RF embarcado para a base Flor de Íris. Em azul: classificador desenvolvido em Python; Em verde: classificador apresentado neste trabalho; Em la- ranja: classificador apresentado por (Abdolrahim & Gaudet).	59
43	Taxa de acurácia para os 13 indivíduos não amputados da base DB2 do repositório NinaPRO.	60
44	Taxa de acurácia em função do movimento para os 13 indivíduos não amputados da base DB2 do repositório NinaPRO.	61
45	Curva de acurácia em função do movimento para o indivíduo 13 da base NinaPRO.	62
46	Matriz de confusão do indivíduo 13 da base NinaPRO.	62

47	Matriz de confusão do indivíduo 11 da base NinaPRO.	63
48	Taxa de acurácia para o indivíduo de testes durante o protocolo experimental.	64
49	Matriz de confusão do indivíduo de testes para o protocolo experimental.	64
50	Tempo de latência necessário para realizar uma classificação em função da quantidade de canais. Em azul: FPGA. Em laranja: Microprocessador ATMega328P.	67
51	Layout da face bottom da placa.	76
52	Matriz de confusão dos usuários 1 a 4 da base NinaPRO.	77
53	Matriz de confusão dos usuários 5 a 8 da base NinaPRO.	77
54	Matriz de confusão dos usuários 9 a 12 da base NinaPRO.	78
55	Validação dos filtros dos canais 3 ao 8.	79

LISTA DE TABELAS

1	Principais características do conversor ADS1198.	34
2	Modo de operação configurado no conversor AD.	34
3	Principais características da FPGA XC6SLX16.	35
4	Características no domínio tempo utilizadas neste trabalho.	37
5	<i>Setup</i> de teste.	46
6	Descrição dos indivíduos não amputados da base NinaPRO.	50
7	Características das bases de dados utilizadas.	50
8	Posicionamento dos 8 pares de eletrodos para a coleta de sinais sEMG.	53
9	SNR obtida em cada canal.	57
10	Taxa de acurácia estratificada por indivíduo.	60
11	Taxa de acerto por movimento para o indivíduo de teste.	65
12	Recursos utilizados.	65
13	Recursos totais utilizados.	66
14	Taxas de frequência máxima e latência do sistema proposto.	66

LISTA DE ABREVIATURAS

ADC	Conversor Analógico Digital
AVC	Acidente Vascular Cerebral
CMRR	<i>Common Mode Rejection Ratio</i>
DSP	<i>Digital Signal Processing</i>
DT	<i>Decision Tree</i>
EMG	Eletromiografia
FFT	<i>Fast Fourier Transform</i>
FPGA	<i>Field-Programmable Gate Array</i>
FIFO	<i>First In First Out</i>
IMC	Índice de Massa Corpórea
LUT	<i>Logical Unit</i>
MUAP	<i>Motor Unit Action Potential</i>
OMS	Organização Mundial de Saúde
RAM	<i>Random Access Memory</i>
RF	<i>Random Forest</i>
RNA	Redes Neurais Artificiais
SDRAM	<i>Synchronous Dynamic Random Access Memory</i>
sEMG	Eletromiografia de Superfície
SPS	<i>Samples Per Second</i>
USB	<i>Universal Serial Bus</i>
WT	<i>Wavelet Transform</i>

1 INTRODUÇÃO

Existem diversas enfermidades relacionadas a distúrbios de movimento, segundo estudo publicado na American Heart Association em 2011 aproximadamente 795.000 pessoas sofrem de AVC anualmente e deste montante estima-se que aproximadamente 26.000 pessoas ficam com sequelas que de alguma maneira interferem na execução de suas tarefas diárias. Nos estudos destas enfermidades existem diferentes técnicas que podem ser aplicadas na análise do movimento. E dentre estas, pode-se destacar a eletromiografia que segundo (KONRAD, P. 2005) consiste em uma técnica experimental, aplicada na aquisição e análise dos sinais mioelétricos provenientes das variações fisiológicas na membrana muscular.

Diversos trabalhos publicados nos últimos anos fazem uso da eletromiografia de superfície (sEMG) para auxiliar nos mais variados diagnósticos, em trabalho apresentado por (SONMEZOCAK & KURT, 2021) a eletromiografia foi utilizada em conjunto com redes neurais artificiais para o diagnóstico de pacientes com bruxismo. Outro estudo para avaliar a perda de potência muscular durante a prática de atividades físicas foi publicado por (SUN *et al.*, 2022; LIU *et al.*, 2022).

De acordo com trabalho publicado por (GRAHAM *et al.*, 2008), estimou-se que no ano de 2005 aproximadamente 1.6 milhões de pessoas sofreram com a perda de movimentos e que ocorreram em torno de 185.000 amputações, apenas nos Estados Unidos. Este é um dado bastante impactante, pois pode alterar drasticamente a qualidade de vida das pessoas afetadas. Neste cenário foi apresentado por (MOSTAFA *et al.*, 2018) um trabalho que propôs um dispositivo sEMG para estimar a força de aperto de pessoas que apresentavam perda de movimentos nas mãos. Em outro trabalho apresentado por (KACZMAREK *et al.*, 2019) foi proposto um sistema baseado em sEMG para a identificação da movimentação da mão humana para a criação de próteses.

Com a evolução tecnológica e científica nas últimas décadas, outras ferramentas foram incorporadas junto a eletromiografia de modo a fornecer um diagnóstico mais ágil e assertivo. O uso de Redes Neurais Artificiais (RNAs) foi amplamente difundido devido sua capacidade de processar e classificar grandes quantidades de dados a partir de

um conhecimento prévio. Seguindo este contexto, (MOSTAFA *et al.*, 2018) propôs um sistema baseado em FPGA com redes neurais artificiais para análise de sinais elétricos provenientes da atividade muscular e para otimizar a análise dos dados a RNA proposta foi treinada com base nos dados fornecidos de repositórios previamente definidos. Em trabalho semelhante apresentado por (CHOI *et al.*, 2010), foi proposto um sistema que se valia do uso de RNAs para a análise dos sinais obtidos via sEMG dos movimentos de contração das mãos para estudos de reabilitação e análise em atividades esportivas.

Diversos estudos buscam desenvolver sistemas classificadores para reconhecimento de movimentos através dos estímulos mioelétricos para o controle de próteses, em um estudo publicado por (GRAHAM *et al.*, 2008), ocorrem anualmente nos Estados Unidos cerca de 185.000 novas amputações. Um trabalho apresentado por (MOSTAFA *et al.*, 2020) foi abordado o uso de RNAs para classificar a força de aperto de próteses em indivíduos amputados.

Além do uso de RNAs para classificação de movimentos, outras técnicas podem ser utilizadas como Árvores de Decisão ou ainda *Random Forests*. Foi apresentado por (OMISORE *et al.*, 2019) um sistema classificador baseado em eletromiografia de superfície para reconhecimento de movimentos das mãos em Random Forest, obtendo uma taxa de acerto superior a 75%.

O objetivo deste trabalho é o desenvolvimento de um sistema embarcado de pequeno porte com custo reduzido que seja capaz de adquirir, processar e através do método *Random Forest* classificar alguns movimentos do segmento mão-braço com base nos dados obtidos através da eletromiografia de superfície. A classificação ocorrerá a partir de características que serão extraídas dos sinais adquiridos em cada movimento pré-determinado e de posse das taxas de acerto obtidas no protótipo desenvolvido, apresentar uma comparação com outras metodologias utilizadas na literatura clássica.

2 CONCEITOS TEÓRICOS

2.1 CONCEITOS SOBRE ELETROMIOGRAFIA

Os primeiros estudos ligados aos sinais mioelétricos datam do século XVII, quando Francesco Redi documentou que a musculatura de arraiais poderiam ser uma fonte de energia elétrica. Os primeiros trabalhos relacionados à eletromiografia de superfície foram publicados em 1960 pelo cientista turco John Basmajian que ficou conhecido como o pai da eletromiografia de superfície (CRISWELL, 2011). Em uma definição mais contemporânea, a eletromiografia consiste na análise elétrica dos sinais provenientes dos nervos, músculos e junções neuromusculares (MERLETTI & PARKER, 2004), (NAM *et al.*, 2019).

Sob o ponto de vista fisiológico, a contração e o relaxamento muscular ocorrem devido à conexão neuromuscular e o início do processo de contração acontece com o estímulo muscular, no qual um sinal elétrico chamado potencial de ação muscular é transmitido às fibras musculares. O emissor deste sinal é o neurônio motor, sendo denominado "unidade motora" o conjunto formado por ele e todas as fibras musculares a ele conectadas (TORTORA & DERRICKSON, 2017). Um único neurônio motor estimula mais de uma fibra muscular, sendo este número associado, principalmente, ao tipo do movimento. Em músculos associados a movimentos de maior precisão, como por exemplo o de abrir e fechar os olhos, os neurônios motores acionam normalmente entre 10 e 20 fibras musculares. Em contrapartida, nos músculos responsáveis por movimentos maiores que requerem mais força (por exemplo o bíceps braquial e o gastrocnêmio), um único neurônio motor pode estar associado a uma faixa de 2000 a 3000 fibras musculares (TORTORA & DERRICKSON, 2017).

Após a ocorrência do estímulo, os impulsos nervosos (potenciais de ação) surgem, geralmente na região chamada cone de implantação, a partir do qual são conduzidos ao longo do axônio até os terminais, os quais estão próximos, porém não fisicamente conectados, às fibras musculares. A sinapse entre os terminais axônicos e a placa motora terminal de uma fibra muscular é chamada de junção neuromuscular. Este conjunto está conectado

ao córtex cerebral através da medula espinhal conforme pode ser observado na Figura 1.




Figura 1: Representação básica do sistema motor humano.

Fonte: Adaptado de (MERLETTI & PARKER, 2004).

O potencial de ação divide-se em duas fases: despolarização e repolarização. Durante a primeira etapa, a membrana parte do repouso (tipicamente apresentando potencial elétrico de -70 mV) para um potencial menos negativo podendo atingir valores positivos. Tipicamente, uma despolarização para um potencial de cerca de -55 mV já caracteriza um impulso (TORTORA & DERRICKSON, 2017). Durante uma contração muscular, o potencial elétrico na região de despolarização pode atingir valores na faixa de 50 a 75 mV (SUN *et al.*, 2022). Na fase de repolarização o potencial da membrana retorna para o seu valor de repouso (TORTORA & DERRICKSON, 2017). A velocidade na qual o potencial de ação se propaga na membrana muscular está relacionada com o diâmetro e o tipo das fibras musculares, sendo denominada de velocidade de condução (MERLETTI & PARKER, 2004). A Figura 2 apresenta a resposta elétrica da membrana muscular durante um estímulo recebido pelo sistema motor.

De acordo com (CRAM, 2003), a eletromiografia pode ser dividida em duas formas: intramuscular e de superfície. A opção intramuscular requer um profissional habilitado pois trata-se de uma técnica invasiva ao corpo, mas possibilita a análise da eletromiografia com maior resolução espacial, limitado de 4 a 5 unidades motoras (MERLETTI & PARKER, 2004). Deste modo, o sinal de EMG medido consiste na superposição de potencial




Figura 2: Resposta elétrica da unidade motora durante o movimento.

Fonte: Adaptado de (TORTORA & DERRICKSON, 2017).

de ação da unidade motora. Enquanto que no modo não invasivo, a medição do sinal de EMG é realizada através de eletrodos fixados sob a pele. Neste caso, os eletrodos, tipicamente constituídos de prata / cloreto de prata, podem ser colocados diretamente em contato com a pele em casos de medição à seco ou com uma camada de gel condutivo separando-os da pele (POZO *et al.*, 2004), (MERLETTI & PARKER, 2004).

O sinal de EMG, medido de forma invasiva ou não, é, portanto, resultado da superposição de várias MUAPs (unidades motoras de ação potencial). Contudo, na leitura superficial, o eletrodo se encontra distante do músculo, sendo o espaço entre ambos preenchido por tecido biológico. Este último atua como um filtro passa-baixa, atenuando frequências acima de 400Hz (POZO *et al.*, 2004). Com isso, o sinal de sEMG possui componentes entre as frequências de 6 e 500 Hz, sendo a maior parcela da energia compreendida na faixa de 20 e 150 Hz. A amplitude do sinal não processado (à exceção da aplicação de um filtro passa banda) pode excursionar entre $\pm 5000\mu V$ em atletas (KONRAD, 2005)

Na Figura 3 é ilustrado um sinal de sEMG adquirido de um voluntário saudável, não amputado. Este sinal pertence à base de dados NinaPro DB-2, voluntário 1 (ATZORI *et al.*, 2014). A atividade elétrica muscular medida da superfície da pele possui forte característica estocástica, podendo ser considerado um sinal não estacionário. Tais atributos estão relacionados ao grande número de MUAP's sobrepostas e da natureza irregular da descarga das unidades motoras. Existe uma série de fatores que influenciam a medição de EMG, seja do ponto de vista fisiológico, anatômico e técnico, que fazem com a que

a relação entre a amplitude do envelope do sinal obtido e a força exercida pela junta ou membro seja apenas qualitativa (DE LUCA, 1997).




Figura 3: Exemplo de um sinal de EMG.

Fonte: Autor

2.2 ASPECTOS GERAIS SOBRE PROCESSAMENTO E MODELOS INTELIGENTES EM sEMG

2.2.1 Extração de Características

O sinal bruto obtido a partir de um sistema de aquisição possui diversas informações que podem ser quantizadas. Porém, devido a sua forte característica estocástica estas informações precisam ser processadas de modo que sejam identificadas corretamente para a criação de modelos preditores. De acordo com (MEENA, 2019) o processo de extração de características é uma técnica fundamental para a análise de sinais EMG e segundo (BOSCHMANN *et al.*, 2019) e (HAKONEN *et al.*, 2015) o sinal de eletromiografia pode ser analisado sob três diferentes aspectos: domínio tempo, domínio frequência e domínio tempo-frequência.

A extração de características no domínio do tempo faz parte da literatura clássica e é amplamente difundida. Existem diversas métricas utilizadas para o devido processamento do sinal bruto (valor RMS, valor médio, potência, comprimento de onda, etc.). A análise no domínio do tempo permite que o sinal bruto seja processado sem qualquer tipo de

transformação, porém, esta análise se torna mais suscetível a interferência gerada por fontes extrínsecas de ruído como frequências provenientes da rede elétrica ou ainda ruídos provenientes do contato entre o eletrodo e a pele (MEENA, 2019).

Alguns trabalhos recentes buscam propor uma alternativa aos métodos clássicos para extração de características. Em trabalho apresentado por (SHI, *et al.*, 2021) foi utilizada a Transformação de Stockwell, apresentada na Equação 1, para extrair as características de um sinal sEMG a partir de 10 ensaios realizados pelos autores. Esta técnica faz uso do domínio tempo-frequência através da combinação entre a FFT (Transformada Rápida de Fourier) e a WT (Transformada de Wavellet) que proporciona observar o sinal adquirido sob o ponto de vista do seu espectro de frequência em diferentes instantes de tempo através da janela gaussiana deslizando.

$$S(\tau, f) = \int_{-\infty}^{+\infty} x(t) \frac{|f|}{\sqrt{2\pi}} e^{-(\tau-t)^2 f^2} e^{-j2\pi ft} dt \quad (1)$$

Onde:

- t: tempo em s;
- τ : ponto central da janela gaussiana;
- f: frequência.

Em outro trabalho apresentado por (NOUGAROU, *et al.*, 2019) foi abordada a extração de características valendo-se da resolução espacial proporcionada pela utilização de 64 eletrodos e a aplicação de filtros monopolar, bipolar e binomial inverso. Este arranjo obteve uma melhoria de aproximadamente 3% na representação do sinal em relação as características extraídas utilizando os métodos clássicos no domínio do tempo.

Uma abordagem nova foi apresentada por (JABER *et al.*, 2020) onde desenvolveu-se uma metodologia para extração de métricas robustas às variações temporais intrínsecas do sinal. Para tanto, considerou-se o sinal adquirido em uma matriz de 8x16 eletrodos como uma imagem e, a partir dela, calculou-se características baseadas na intensidade de cada píxel (nível de ativação de um eletrodo) e no Histograma de Gradientes Orientados. A partir das informações espaciais supracitadas, atingiu-se taxas de acerto acima de 90% para 9 dos 10 voluntários considerados, na classificação de 8 movimentos com SVM. Contudo, os dados utilizados foram adquiridos em seções realizadas em dias distintos, salientando a capacidade de absorção de informações invariantes no tempo do algoritmo proposto, proporcionando um modelo mais robusto a tal fator de confusão.

A escolha das características é frequentemente considerada mais relevante do que a técnica que será utilizada no sistema de controle (ENGLEHART *et al.*, 1999). Isto se deve a característica altamente estocástica do sinal de eletromiografia. Este processo representa uma etapa extremamente importante da análise do sinal adquirido, pois, a acurácia do classificador está diretamente relacionada a característica utilizada para análise (HAKONEN *et al.*, 2015).

2.2.2 Classificadores

As técnicas de aprendizagem de máquina podem ser divididas em dois grupos: supervisionado e não-supervisionado. O sistema é dito supervisionado quando possui um conjunto de entradas e alvos utilizados como ponto de partida para o classificador, e dito não-supervisionado quando o próprio classificador deve agrupar os dados com base em métricas de qualidade sem ter o alvo especificado. Um exemplo de um método não-supervisionado é o *clustering*. É no processo de treinamento que se concentra todo aprendizado adquirido, sendo dele a responsabilidade de decodificar os padrões de sinal de EMG em intenções de movimentos e dentre as diversas técnicas de aprendizado supervisionado existentes cabe destacar algumas:

- SVM;
- Redes Neurais;
- Árvores de Decisão;
- *Random Forests*.

Árvores de Decisão e *Random Forests* serão abordadas mais detalhadamente nas próximas seções devido ao fato de fazerem parte do escopo deste trabalho.

2.2.2.1 Árvores de Decisão

De acordo com (KULAGA & GORGON, 2015) e (JAWORSKI *et al.*, 2018), árvores de decisão (DT) são utilizadas em diversas aplicações como finanças, marketing, reconhecimento de movimentos até em sistemas para detecção de intrusão devido a sua simplicidade e transparência. Segundo (ALCOLEA & RESANO, 2021) este uso se dá pelo fato de que árvores de decisão constituem uma técnica bastante efetiva para resolução de problemas, pois são desenvolvidas a partir de uma estrutura hierárquica de decisões e suas consequências. A Figura 4 ilustra a representação de uma árvore de decisões para análise de empréstimos em uma instituição financeira em que o critério de aprovação do empréstimo é realizado após uma série de decisões baseadas em critérios pré-definidos.

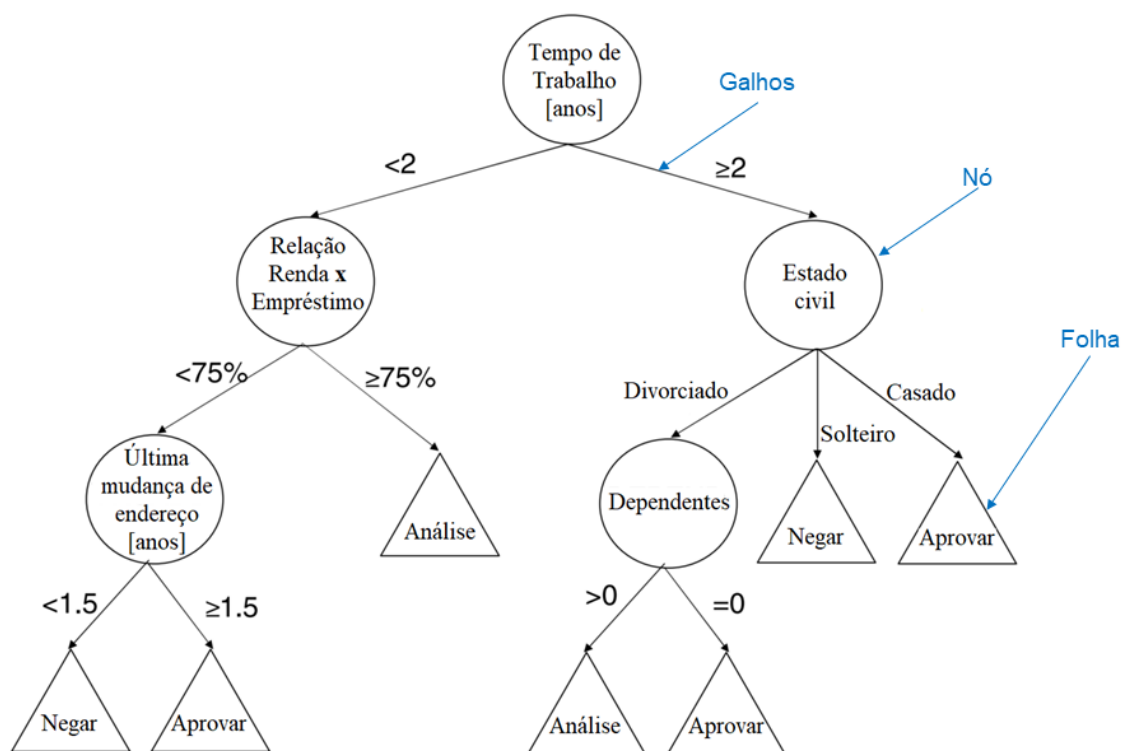


Figura 4: Exemplo de uma árvore de decisão utilizado como classificador em um sistema de empréstimos.

Fonte: Adaptado de (ROKACH & MAIMON, 2015).

Observando a Figura 4, os nós representam as características de interesse para a classificação do processo em análise e nota-se que cada nó sub-divide a instância em dois ou mais galhos que levam a uma nova tomada de decisão e cada folha é associada a uma classe de modo a representar o alvo desejado. De acordo com (ROKACH & MAIMON, 2015), a acurácia de uma árvore de decisão é determinada pelo equilíbrio entre diferentes parâmetros como a quantidade de nós, quantidade de folhas, profundidade da árvore ou ainda pelo número de atributos utilizados.

Para a adequada implementação de uma árvore de decisão é necessário compreender a maneira mais adequada para realizar a ramificação dos galhos e quais critérios devem ser adotados para a parada da árvore. De acordo com (ROKACH & MAIMON, 2015), a ramificação dos galhos normalmente é realizada de acordo com o valor de um atributo único. Segundo a literatura, os critérios para ramificação mais utilizados são:

- Baseado em Impurezas;
- Ganho;
- Critério Ortogonal;
- Index de Gini.

Durante o processo de parada, também conhecido como poda, os critérios mais utilizados são:

- Todas as instâncias no conjunto de teste convergem para um único valor de *target*;
- A profundidade máxima da árvore foi atingida;
- O número de casos em que a quantidade de nós terminais é menor que a quantidade de nós intermediários;
- O critério ideal de ramificação

Segundo (ROKACH & MAIMON, 2015), as métricas de desempenho mais comumente utilizadas para classificadores são: Acurácia e *F-Score*. A definição de Acurácia e *F-Score* são apresentadas nas Equações 2 e 3 respectivamente.

$$Acuracia[ACC] = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$F - Score = \frac{2 * TP}{2 * TP + FP + FN} \quad (3)$$

Onde:

- TP: Positivo verdadeiro;
- TN: Negativo verdadeiro;
- FP: Falso positivo;
- FN: Falso negativo.

Árvores de Decisão são o "coração" da técnica conhecida como *Random Forests* que será abordada na próxima seção.

2.2.2.2 *Random Forests*

A teoria apresentada por Leo Breiman em 2001 define as *Random Forests* (RF) como um classificador composto por uma coleção de árvores classificadoras estruturadas, ou ainda em outras palavras, RF's podem ser generalizadas como uma combinação de Árvores de Decisão (LIU *et al.*, 2012). Segundo (BREIMAN, 2001) cada classificador é dado por: $\{h(x, \Theta_k), k = 1, \dots\}$, em que $\{\Theta_k\}$ representa um vetor independente gerado de maneira aleatória e $\{x\}$ representa o vetor de entrada. Assumindo que a RF é composta por vários classificadores $\{h(x, \Theta_k), k = 1, \dots\}$, após 'k' execuções obtém-se uma

sequência de classificadores dada por: $\{h_1(x), h_2(x), \dots, h_k(x)\}$, com isto pode-se obter a composição do resultado final do classificador através da votação dada pela Equação 4.

$$H(x) = \operatorname{argmax}_Y \sum_{i=1}^k I(h_i(x) = Y) \quad (4)$$

Onde:

- $H(x)$: combinação do modelo de classificação;
- h_i : resultado de uma única árvore de decisão;
- $I(\cdot)$: função indicador;
- Y : variável de saída.

O processo de criação deste vetor independente é também conhecido como *bootstrap*, este processo consiste em criar outros conjuntos de dados ordenados de maneira aleatória a partir do conjunto de dados original (ZHOU *et al.*, 2020). A partir deste processo, é criada uma árvore de decisão para cada novo conjunto de dados que foi criado na etapa de *bootstrap*. De acordo com (BUSCHJÄGER & MORIK, 2018), este processo reduz o efeito do *overfitting*, ao contrário do que pode ocorrer em uma aplicação de Árvores de Decisão comum em que todos os dados são utilizados pela mesma DT. De acordo com (CUTLER *et al.*, 2011) e (BUSCHJÄGER & MORIK, 2018), o critério utilizado para a ramificação das árvores que compõe a RF é o Índice de Gini ou critério de impureza de Gini, representado pela Equação 5.

$$G_i = 1 - \sum_{k=1}^n p_{i,k}^2 \quad (5)$$

Em que $p_{i,k}$ é dado por:

$$p_{i,k} = \frac{p_i}{p_k} \quad (6)$$

Onde:

- p_i : valor da amostra 'k';
- p_k : quantidade de amostras adquiridas.

Segundo (ATHEY *et al.*, 2018) todas as árvores são simétricas, com isto sua saída é invariante a permuta de índices de treino e isto agrega robustez ao processo de classificação. Atualmente, as *Random Forests* são um dos algoritmos mais utilizados para classificação ou regressão, devido a sua capacidade de classificar grandes conjuntos de dados. A Figura 5 representa o fluxograma para elaboração de uma RF.

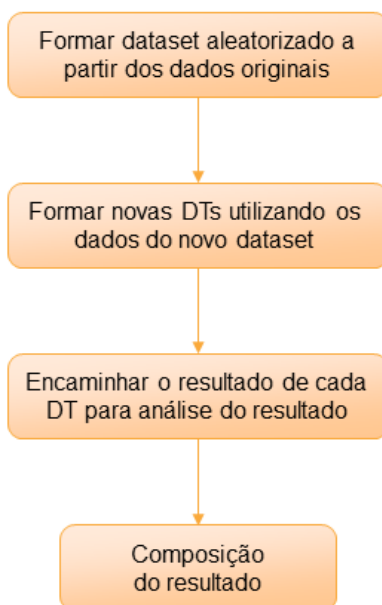


Figura 5: Fluxograma de criação de *Random Forests*.

Fonte: Autor.

A Figura 6 ilustra a capacidade que a *Random Forest* possui de processar diversas árvores em paralelo, otimizando o tempo de execução até que se obtenha o resultado final. De acordo com (SUTHAHARAN, 2016) este paralelismo possibilita que a classificação seja realizada utilizando diferentes características, devido ao processo de *bootstrap* e isso contribui para elevar a acurácia do modelo de aprendizado. Ainda segundo (GOKGOZ & SUBASI, 2015), *Random Forests* tem grande utilização para classificação de sinais biomédicos devido as suas vantagens quando utilizadas para classificação de conjuntos de dados de diferentes tamanhos.

Existem alguns trabalhos que propõem o uso de Árvores de Decisão ou *Random Forests* como classificadores para reconhecimento de movimentos. Em trabalho apresentado por (FINDIK *et al.*, 2020) foi implementado um classificador baseado em RF para reconhecimento de movimentos dos dedos utilizando sinais de eletromiografia. Em outro trabalho apresentado por (SU *et al.*, 2016) foi desenvolvido um sistema classificador baseado em RF para reconhecimento de linguagem de sinais utilizando os dados obtidos através de acelerometria e eletromiografia.

O uso de classificadores em conjunto com a eletromiografia vem sendo utilizado em diferentes áreas de interesse, foi apresentado por (BRIOUZA *et al.*, 2022) um sistema

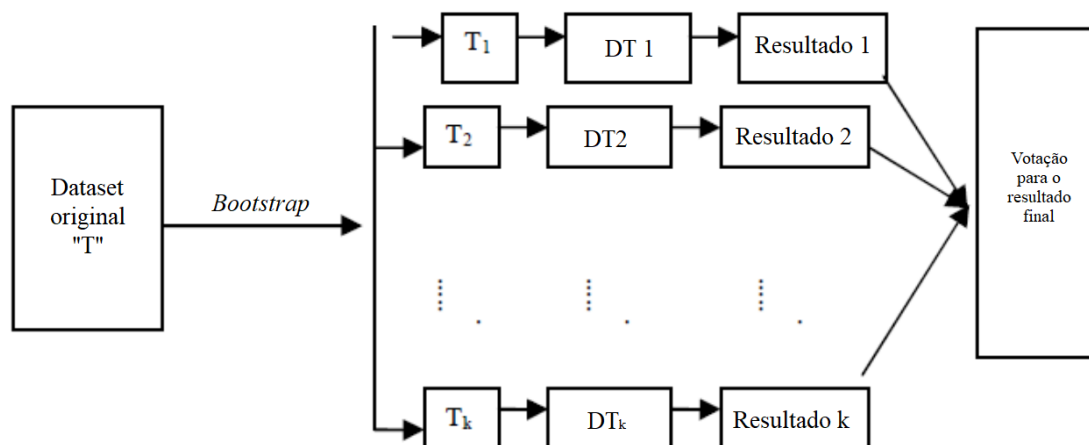


Figura 6: Processo de execução de uma *Random Forest*.

Fonte: Adaptado de (LIU *et al.*, 2012).

baseado em RF para a reabilitação dos movimentos dos membros superiores utilizando apenas características extraídas no domínio tempo. Em outra linha de trabalho, foi proposto por (LIANG *et al.*, 2022) um sistema classificador baseado em RF para análise de escoliose.

Outros trabalhos relacionados a reconhecimento de movimentos foram apresentadas por (ZHOU *et al.*, 2020) e (KUNDU, 2021) para o uso em controle de próteses, de modo a auxiliar na recuperação de indivíduos amputados. Em trabalho similar, (CHEN, 2022) apresentou um sistema classificador para controlar um exoesqueleto a fim auxiliar na articulação dos membros inferiores de pacientes em tratamento para recuperação dos movimentos das pernas.

2.2.3 Sistemas Embarcados

De acordo com (VAN ESSEN *et al.*, 2012) o uso de classificadores embarcados em FPGA apresentam uma melhor relação entre taxa de acerto e consumo de potência em comparação com classificadores desenvolvidos em CPU's multi-núcleos. Trabalho semelhante foi proposto por (ZHU *et al.*, 2022) em que foi realizada a comparação entre uma RF embarcada em uma FPGA Intel Stratix V com uma RF executada por um processador com arquitetura x86. Neste cenário de testes foi observada uma redução de 40 vezes no tempo de processamento da RF embarcada na FPGA.

Diversos estudos vem sendo publicados nos últimos anos buscando adequar o desempenho dos sistemas classificadores com as limitações de hardware características das FPGAs de modo a potencializar seu desempenho. Isso motivou o trabalho apresentado por (JINGJUI *et al.*, 2018) em que os autores propõem a combinação do método de clusterização k-Means com RF para reduzir a demanda de hardware necessária para realizar

uma classificação, esta abordagem apresentou uma redução de 41% no número de LUTs (unidades lógicas) utilizadas para o processo completo.

A crescente utilização de dispositivos com comunicação sem fio e o avanço do IoT, fizeram o desenvolvimento de dispositivos portáteis ganharem relevância. Neste contexto foi apresentado por (VENUTO & MEZZINA, 2019) um dispositivo portátil, embarcado em FPGA para aquisição de sinais de eletromiografia e transmissão para um servidor em tempo real para pós-processamento.

Em outro trabalho apresentado por (BARONE & MERLETTI, 2013) foi proposto um sistema portátil para aquisição e análise de sinais de sEMG em tempo real e em trabalho semelhante apresentado por (MAJOLO, 2019; MEENA, 2019) foi apresentado um classificador baseado em máquinas de vetor de suporte embarcado em FPGA para caracterização de sinais mioelétricos com uma taxa de acurácia de aproximadamente 88%.

O uso de classificadores embarcados em sistemas de porte reduzido pode auxiliar em diferentes tarefas, como controle de próteses ou monitoramento de atividades ao ar livre por exemplo. Foi apresentado por (VENUTO & MEZZINA, 2019) um sistema de pequeno porte embarcado em FPGA em sistema SoC, o objetivo deste trabalho era a aquisição de 6 canais de sEMG conectados nos membros inferiores do corpo humano para análise dinâmica do comportamento das fibras musculares durante a corrida. Proposta semelhante foi apresentada por (WHÖRLE *et al.*, 2017) em que foi apresentado um sistema embarcado para predição de movimentos com base em sinais de sEMG e ECG para reabilitação neuro-muscular.

Uma série de disfunções neurológicas podem ser diagnosticadas através da adequada compreensão da atividade elétrica muscular. Foi abordado por (YEE *et al.*, 2023) a utilização de uma SVM embarcada para diagnóstico de distúrbio conhecido como espasticidade, esta é uma enfermidade decorrente de lesões congênicas ou adquiridas no sistema nervoso central. A SVM apresentada neste trabalho obteve uma acurácia de 81% no diagnóstico de espasticidade.

A comunicação humana seja ela falada ou escrita, é composta por uma complexa combinação de fatores para que seja possível a propagação de intenções entre diferentes indivíduos. Neste contexto, a gesticulação assume um papel complementar a comunicação oral ou ainda é utilizada como meio de comunicação principal para indivíduos com deficiência auditiva. Em trabalho apresentado por (SONG *et al.*, 2019) foi embarcado um sistema classificador baseado em árvores de decisão para reconhecimento de 12 movimentos das mãos com base nos dados do repositório Nina-PRO. Este classificador obteve uma acurácia de 91% considerando a extração de 9 características no domínio do tempo.

3 METODOLOGIA EXPERIMENTAL

Conforme já mencionado nas seções anteriores, o presente trabalho compreende um protótipo para aquisição e classificação de movimentos realizados pelo segmento mão-braço do corpo humano. O diagrama de blocos do sistema proposto neste trabalho é apresentado na Figura 7. Este diagrama é dividido em dois grandes blocos que serão discutidos separadamente: *Circuito de condicionamento* e *Bloco de processamento*. O bloco de processamento foi desenvolvido na plataforma de desenvolvimento PISWORDS que contém uma FPGA Spartan XC6SLX16 da Xilinx e a interface de saída do protótipo é realizada através de um microcontrolador ESP-32.

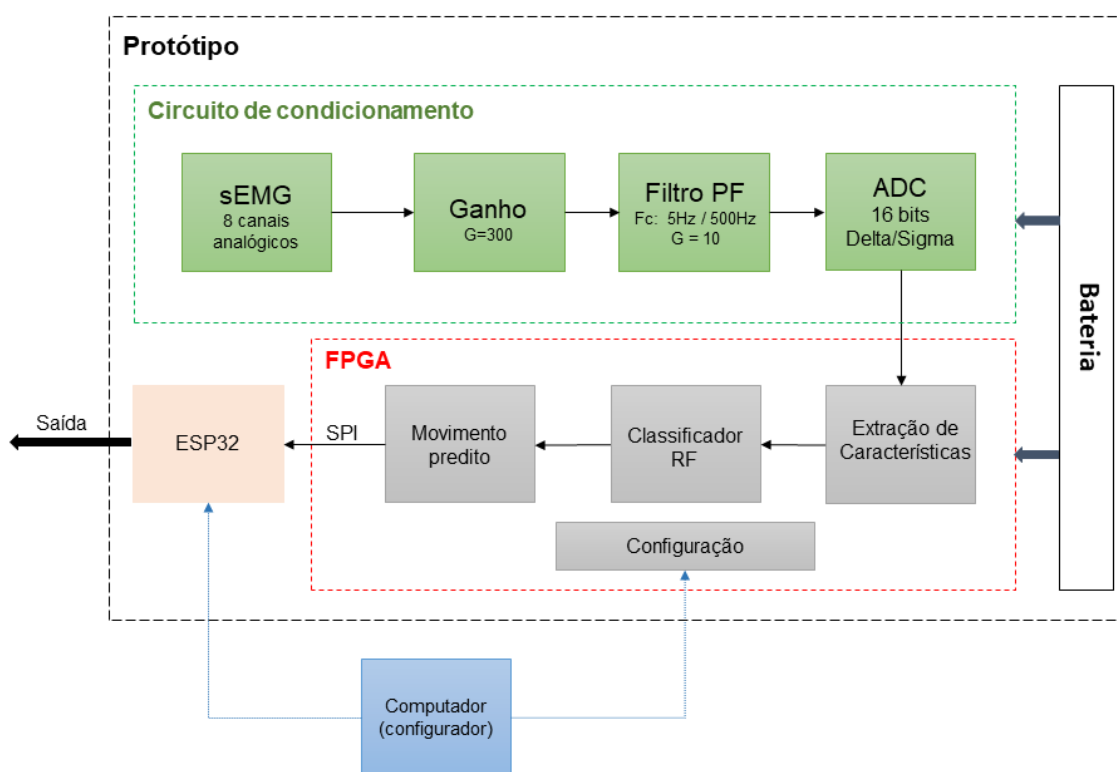


Figura 7: Diagrama de blocos do sistema proposto neste trabalho.

Fonte: Autor.

A captação do sinal mioelétrico é realizada por 8 eletrodos de superfície fixados no

braço em lugares previamente determinados. Estes sinais passam por um amplificador de instrumentação com ganho de 300 e por dois estágios de filtragem. O primeiro para altas frequências e o segundo para baixas frequências. Após os estágios iniciais de amplificação e filtragem, o sinal obtido dos 8 canais é digitalizado através de um conversor tipo *Delta-Sigma* com 16 bits de resolução para cada canal.

O sinal digital é enviado para o bloco de processamento através da interface de comunicação SPI entre o conversor AD e a FPGA utilizada. A extração de características e a classificação do movimento são realizadas pela FPGA e o resultado é enviado a um microcontrolador ESP-32 responsável pela saída do circuito através de uma comunicação SPI.

A confecção do diagrama esquemático e roteamento da placa de circuito impresso foi realizada utilizando a licença de estudante do software Altium Designer versão 22.7.1 com suporte a *MS-Windows 11*. Na Figura 8 é apresentada a simulação 3D do protótipo desenvolvido para este trabalho. Na face superior da placa estão localizados os sinais de entrada dos 8 canais, os amplificadores de ganho, todo o bloco de processamento e os canais 1 até 4. Na face inferior fica localizado o circuito de alimentação e os canais 5 até 8. A disposição dos canais em faces diferentes foi realizada para que a variação entre o comprimento das trilhas que ligam a saída dos circuitos de filtros de cada canal até o conversor AD fosse a menor possível.

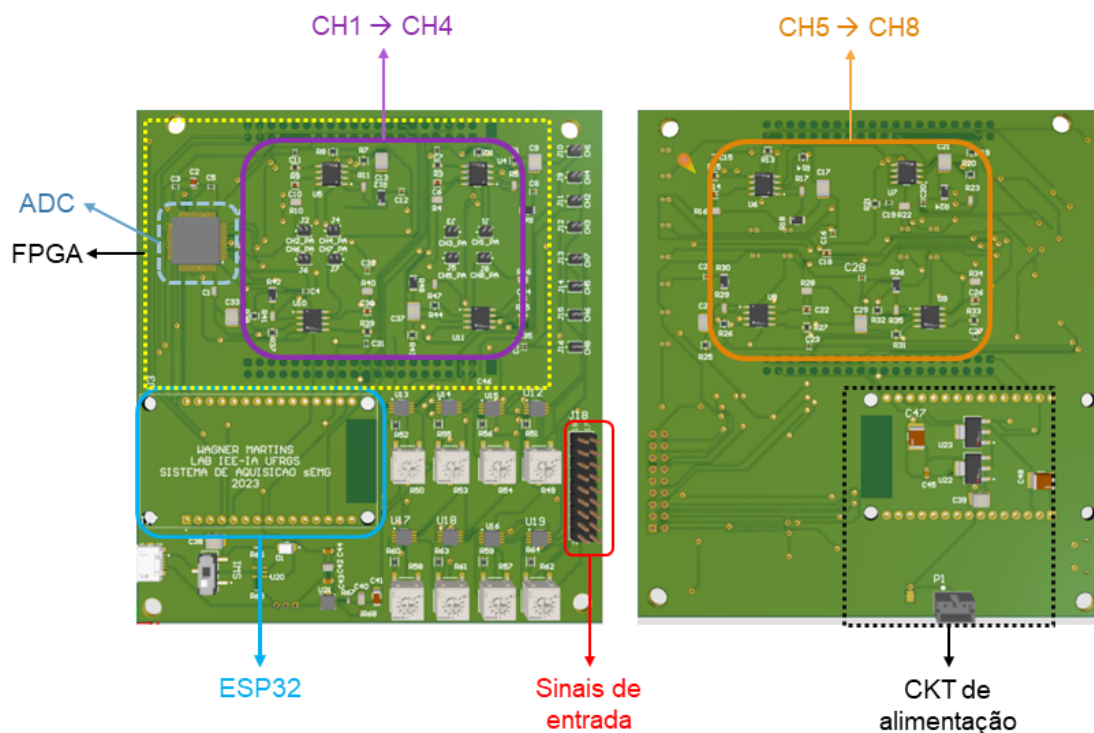


Figura 8: Representação 3D do protótipo proposto.

Fonte: Autor.

Na Figura 9 é possível visualizar o protótipo completamente montado, já com a FPGA e o ESP-32 montados.




Figura 9: Protótipo implementado.

Fonte: Autor.

3.1 ETAPA DE AQUISIÇÃO E CONDICIONAMENTO

De acordo com (JIA *et al.*, 2021) o correto dimensionamento do circuito analógico é crucial para que o classificador possua um desempenho adequado. O primeiro estágio do bloco de condicionamento é o circuito de ganho, composto por um amplificador de instrumentação AD8221 da *ANALOG DEVICES* e a Figura 10 apresenta o esquemático de um canal. Este amplificador possui um CMRR mínimo de 80dB quando aplicada uma frequência de 10kHz. De acordo com o fabricante, o ganho de saída é determinado pela Equação 7 em que R_G é dimensionado de modo a se obter o ganho desejado.

$$G = 1 + \frac{49.4k\Omega}{R_G} \quad (7)$$

Devido as características do sinal de eletromiografia que pode variar entre algumas dezenas de μV até mV (MENDES *et al.*, 2015), optou-se por utilizar um sistema de ganho variável flexibilizando assim a aplicação do circuito para sinais com diferentes ordens de grandeza. Neste contexto, foi definido que $100\Omega \leq R_G \leq 50.1k\Omega$ para que seja possível ajustar o ganho de entrada do circuito. Substituindo os valores de R_G na Equação 7 obtém-se a relação para os valores máximo e mínimo do ganho de entrada.

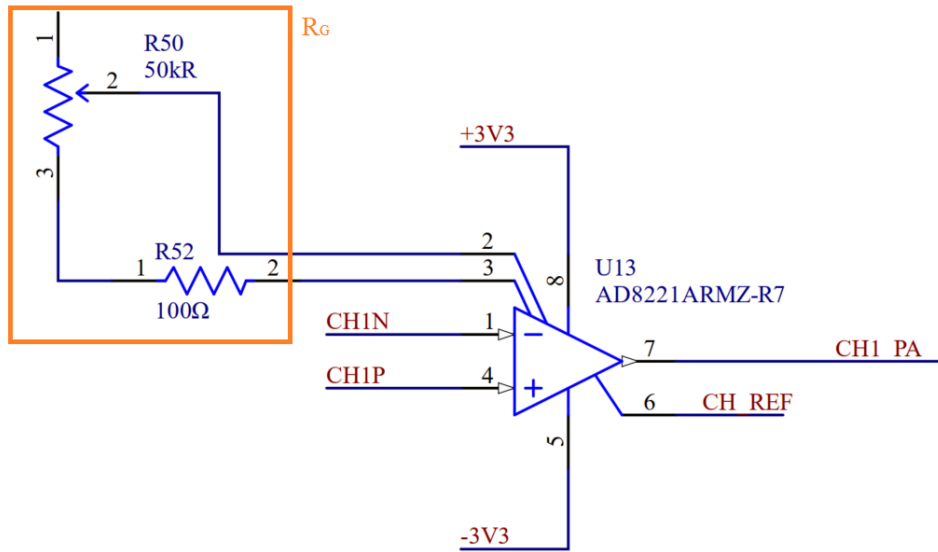


Figura 10: Circuito com ganho ajustável utilizado neste trabalho.

Fonte: Autor.

$$1 + \frac{49.4k\Omega}{100} \leq G \leq 1 + \frac{49.4k\Omega}{50,1k} \quad (8)$$

$$1,98 \leq G \leq 495 \quad (9)$$

As entradas diferenciais CH1N e CH1P são conectadas ao eletrodo fixado no braço e o sinal CH_REF é conectado ao eletrodo de referência. Para garantir a correta aquisição do sinal de eletromiografia que alterna entre valores positivos e negativos, o circuito possui alimentação simétrica de ± 3.3 Volts.

A seguir, vem a etapa de filtragem que é extremamente importante pois para a correta interpretação do sinal adquirido, é necessário compreender em qual faixa de frequência está localizada a informação desejada. Diversos trabalhos (GEETHANJALI & RAY, 2014); (HAKONEN *et al.*, 2015); (KOUTSOFTIDIS *et al.*, 2022); (LIU *et al.*, 2021) citam que para um sinal de eletromiografia a informação pertinente está contida entre as frequências de 10Hz a 500Hz. Para o design do filtro passa baixas, foi utilizado um filtro de *Butterworth* de segunda ordem com frequência de corte de 5Hz e topologia *Sallen-Key* devido a sua menor complexidade de implementação.

De acordo com (NILSON & RIEDEL, 2009) a função de transferência de um filtro passa altas de segunda ordem com ganho unitário, frequência de corte f_c e fator de qualidade Q é dada pela Equação 10.

$$H(s) = \frac{s^2}{s^2 + \frac{2\pi \cdot f_c \cdot s}{Q} + (2\pi \cdot f_c)^2} \quad (10)$$

Sendo:

$$f_c = \frac{1}{\sqrt{R_1 \cdot R_2 \cdot C_1 \cdot C_2}} \quad (11)$$

$$Q = \frac{\sqrt{R_1 \cdot R_2 \cdot C_1 \cdot C_2}}{R_2(C_1 + C_2)} \quad (12)$$

A Figura 11 ilustra o filtro utilizado neste trabalho com os seguintes parâmetros: $f_c = 5Hz$ e $Ganho_{V_o/V_i} = 10$.




Figura 11: Filtro ativo passa altas *Butterworth* de segunda ordem com frequência de corte de 5Hz.

Fonte: Autor.

Para suprimir os sinais de alta frequência foi ligado em cascata com o bloco de altas frequências um filtro ativo passa-baixas com frequência de corte de 500Hz, foi mantido o mesmo amplificador operacional AD8221. Foi implementado um filtro do tipo *Butterworth* de segunda ordem, com topologia *Sallen-Key* cuja função de transferência é representada pela Equação 13 (NILSON & RIEDEL, 2009) com frequência de corte f_c e fator de qualidade Q . A implementação deste filtro é apresentada na Figura 12.

$$H(s) = \frac{(2 \cdot \pi \cdot f_c)^2}{s^2 + \frac{2 \cdot \pi \cdot f_c \cdot s}{Q} + (2 \cdot \pi \cdot f_c)^2} \quad (13)$$

Sendo:

$$f_c = \frac{1}{2 \cdot \pi \cdot \sqrt{R_1 \cdot R_2 \cdot C_1 \cdot C_2}} \quad (14)$$

$$Q = \frac{\sqrt{R_1 \cdot R_2 \cdot C_1 \cdot C_2}}{C_1(R_1 + R_2)} \quad (15)$$

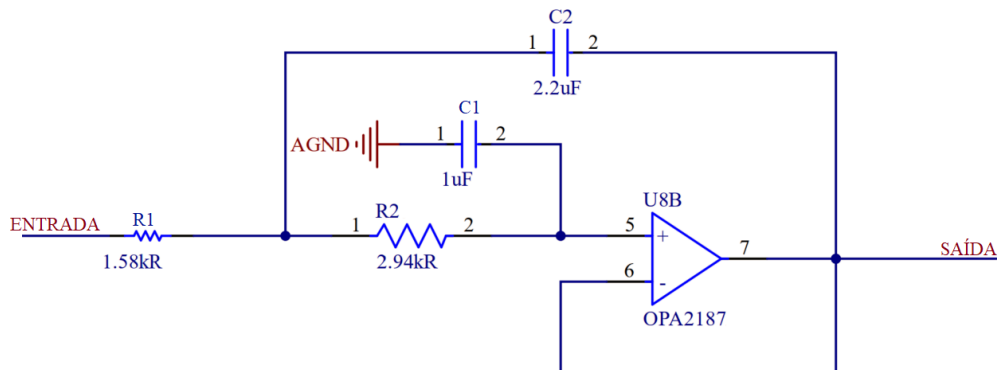


Figura 12: Filtro passa baixas *Butterworth* de segunda ordem com frequência de corte de 500Hz.

Fonte: Autor.

O circuito utilizado como *front-end* para a conversão do sinal analógico após os estágios de amplificação e filtragem será o conversor analógico-digital ADS1198 da *Texas Instruments*. Este é um conversor do tipo *Delta-Sigma* e sua aplicação é dedicada ao uso de sinais biopotenciais. A Figura 13 apresenta um diagrama de blocos simplificado das conexões internas do conversor incluindo as interfaces que serão utilizadas neste trabalho. Neste diagrama pode-se destacar as entradas diferenciais e os sinais de controle e a interface serial utilizada para configuração do dispositivo e transmissão dos dados digitalizados. A frequência de corte dos filtros foi determinada considerando que o conversor AD poderá operar com uma taxa de amostragem de até 8kSPS (*Samples Per Second*), embora os testes tenham sido realizados utilizando a frequência de amostragem de 2kSPS.

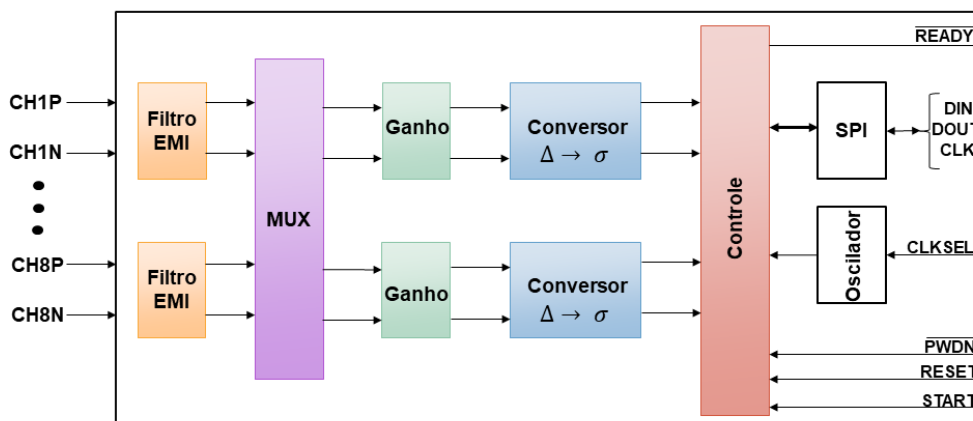


Figura 13: Diagrama de blocos simplificado do ADS1198.

Fonte: Adaptado de Texas Instruments, 2011.

A Tabela 1 apresenta as principais características deste componente, dentre as quais vale destacar a possibilidade de ganho ajustável e o baixo consumo de potência. O alto CMRR indica a elevada capacidade de rejeição para sinais de modo comum, o que é interessante para sinais de baixa amplitude.

Tabela 1: Principais características do conversor ADS1198.

Parâmetro	Valor
<i>Clock</i>	2.048MHz
CMRR	-105dB
Ganho programável	1, 2, 3, 4, 6, 8 ou 12
Potência	550 μ W por canal
Resolução	16 bits por canal
Ruído de entrada	12 μ V _{pp} , para Ganho=6
Taxa de amostragem	até 8kSPS
Alimentação analógica	2.7 ≤ V ≤ 5.25
Alimentação digital	1.65 ≤ V ≤ 3.6

A configuração deste dispositivo é realizada através da interface SPI e na Tabela 2 são apresentados os modos de operação do conversor durante a etapa de aquisição de dados.

Tabela 2: Modo de operação configurado no conversor AD.

Parâmetro	Valor
<i>Clock</i> interno	2.048MHz
Ganho	Unitário
Modo de operação	Leitura contínua
Taxa de amostragem	2kSPS
Tensão de referência	Externa, ±3.3V

3.2 ETAPA DE PROCESSAMENTO

O bloco de processamento e classificação é controlado pela FPGA XC6SLX16 da XILINX, através do kit de desenvolvimento fornecido pela PISWORDS®, ilustrada na Figura 14. A IDE que oferece suporte para a programação desta FPGA é a ISE Design versão 14.6 da Xilinx com suporte para *MS-Windows 7*. Este kit fornece 1 banco de memória SDRAM de 8Mb externa e interface de comunicação USB para configuração da

FPGA. A escolha por uma FPGA embarcada em um kit de desenvolvimento foi realizada com a finalidade de reduzir a complexidade do circuito desenvolvido para este protótipo.



Figura 14: Kit de desenvolvimento da PISWORDS.

Fonte: Autor.

O uso de FPGA's para classificação é interessante devido a sua capacidade de paralelismo, o que pode reduzir consideravelmente o tempo de execução de tarefas mais complexas (ELNAWAYY & SAGAHYROON, 2020). A escolha da FPGA que será utilizada para embarcar o modelo inteligente deve levar em consideração seus aspectos construtivos como a quantidade de unidades lógicas (LUT), quantidade de Flip-Flops e o total de portas de I/O disponíveis. A Tabela 3 apresenta as características mais relevantes da FPGA utilizada neste trabalho.

Tabela 3: Principais características da FPGA XC6SLX16.

Parâmetro	Valor
<i>Clock</i>	50MHz
Memória	576kb RAM
Unidades lógicas	14.579
Flip-Flops	18.224
Portas de I/O	232 portas divididas em 4 bancos

O fluxograma de funcionamento da unidade de controle e classificação é apresentado na Figura 15. Neste fluxograma é interessante destacar os blocos de calibração, extração de características e votação que serão discutidos separadamente nas próximas subseções.

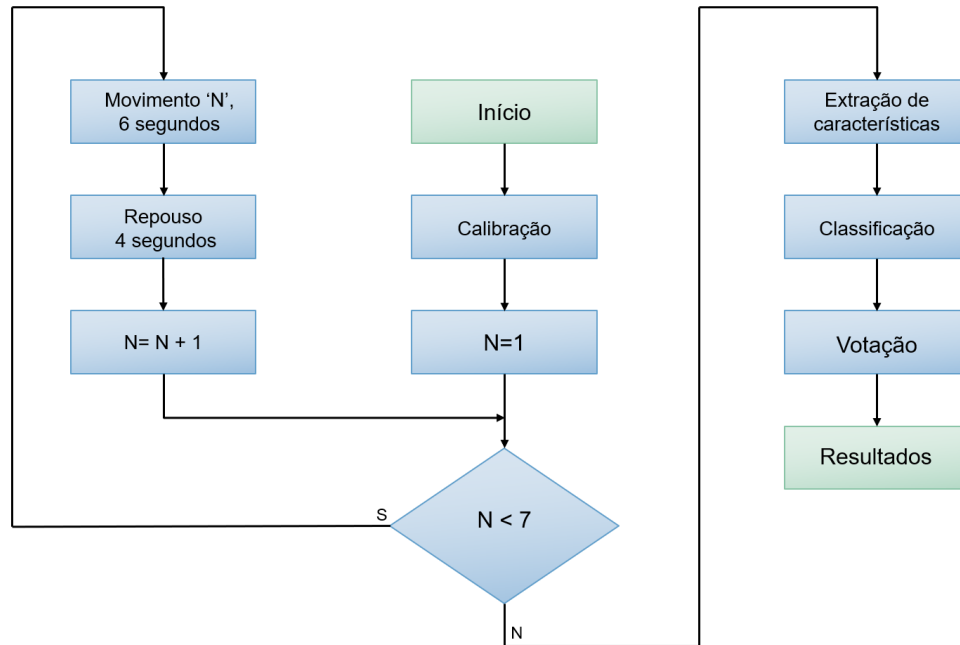


Figura 15: Fluxograma de operação da etapa de controle.

Fonte: Autor.

A rotina de calibração do sistema é realizada na posição de repouso, visto que esta é a posição de menor variabilidade dos sinais mioelétricos entre os diferentes voluntários. O fluxograma de calibração embarcado no sistema é apresentado na Figura 16. O voluntário posiciona o braço na posição de repouso por 5 segundos alternando com movimento de flexão da mão e retornando a posição de repouso. Este processo é repetido 3 vezes durante a inicialização do sistema. Na Figura 16 é apresentado o fluxograma da rotina de calibração do sistema, esta rotina é utilizada para indicar ao sistema que o estado de inicialização é a posição de repouso.

3.2.1 Extração de características em VHDL

Segundo (SONG *et al.*, 2019), devido a sua baixa complexidade de utilização, as características no domínio tempo são mais comumente utilizadas no estudo do reconhecimento de movimentos. A Tabela 4 apresenta as características no domínio tempo utilizadas neste trabalho.

Onde ' N ' denota o tamanho da janela de observação e ' i ' a amostra calculada do vetor de entrada ' x '.

Devido a característica do sinal ser extremamente estocástica, o uso de algumas técnicas de segmentação podem ser utilizadas de modo a auxiliar na análise da informação obtida. Uma das técnicas de segmentação mais utilizada segundo a literatura, (PENG *et al.*, 2022), (XUE *et al.*, 2019), é a de janela deslizante, onde o sinal adquirido deve ser segmentado em janelas de no máximo 300ms com uma sobreposição de 50% entre as janelas

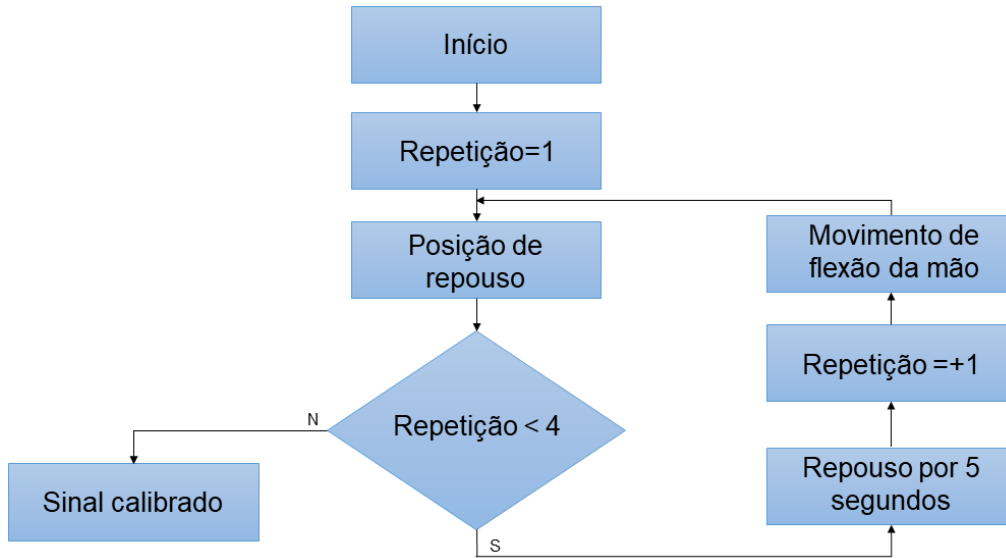


Figura 16: Fluxograma de calibração do sistema proposto.

Fonte: Autor.

Tabela 4: Características no domínio tempo utilizadas neste trabalho.

Característica	Equação
Valor Médio Absoluto (MAV)	$X_{MAV} = \frac{1}{N} \sum_{i=1}^N x_i $
Valor RMS	$X_{RMS} = \sqrt{\frac{\sum_{i=1}^N x_i^2}{N}}$
Potência	$X_{POT} = \frac{1}{N} \sum_{i=1}^N x_i^2$
Comprimento de onda (WL)	$X_{WL} = \sum_{i=1}^N x_{i+1} - x_i $

subsequentes. A Figura 17 ilustra a técnica de janelamento utilizada neste trabalho.

Os dados brutos são adquiridos com uma taxa de $2kSPS$ conforme a Tabela 2. Estes dados são representados pela matriz $S = \{S_{i,k}, g_{i,k}\}$ sendo $S_{i,k}$ uma matriz com 8 colunas representando cada um dos canais adquiridos e $g_{i,k}$ o vetor de identificação do movimento realizado durante a aquisição. O sinal adquirido é segmentado em janelas de 300ms com deslocamento de 150ms, resultando em uma nova matriz dada pela Equação 16. Em que $S_{j,k}$ é o dado segmentado e $g_{i,k}$ representa o identificador do movimento realizado.

$$S' = (S_{j,k}, g_{i,k}) \quad (16)$$

A Equação 16 resulta em uma matriz 33x280 em que o número de colunas é dado pelo identificador do movimento em conjunto com quantidade de características multiplicado pelo total de canais utilizados para análise. Enquanto que o número de linhas é definido pela quantidade de janelas que cabem dentro de um ciclo completo de aquisição, este ciclo é composto pela aquisição dos 7 movimentos que integram o protocolo de ensaios.

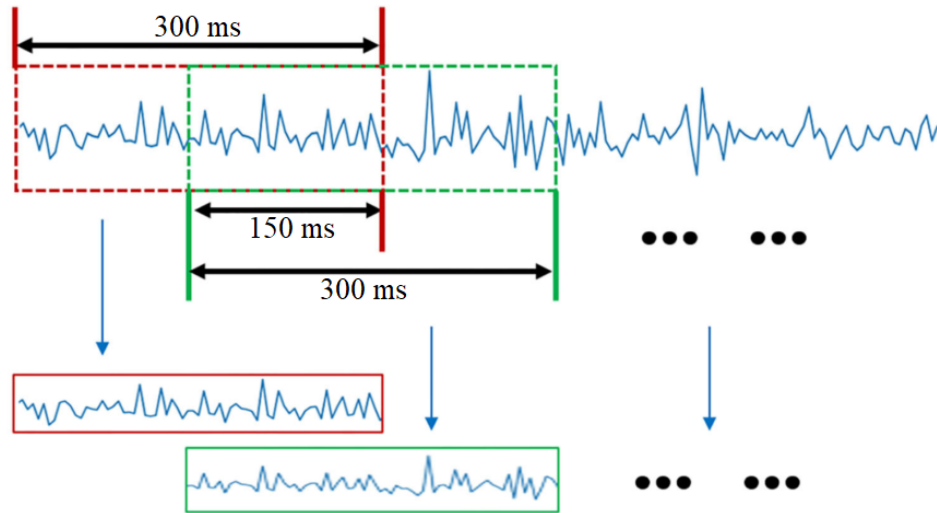


Figura 17: Janela retangular deslizante para a extração de características do sinal de eletromiografia.

Fonte: Adaptado de (PENG *et al.*, 2022).

Conforme apresentado na Tabela 4, a extração de características envolve uma série de operações matemáticas como multiplicação, divisão e somas recursivas. A implementação em VHDL destas operações requer alguma manipulação, pois, operações como multiplicação e divisão são extremamente custosas sob o ponto de vista de hardware quando realizadas por FPGAs que não possuem o auxílio de DSPs (CARRO, 2001).

Os somatórios ao longo do tempo foram implementados em VHDL através do uso de acumuladores e um bloco de memória RAM de modo a implementar a recursividade do somatório, a representação matemática de um acumulador é ilustrada na Equação 17:

$$Acc(n) = \sum_{i=1}^N \alpha_i = \sum_{i=0}^{N-1} \alpha_{n-i} \quad (17)$$

Onde:

- N: tamanho do acumulador;
- α : amostra na entrada do acumulador;
- n: tempo.

Considerando a Equação 17 válida apenas para o tempo atual, os termos de tempo futuro (n+1) podem ser representados pela Equação 18.

$$Acc(n+1) = \sum_{i=0}^{N-1} \alpha_{n-i+1} = \sum_{i=-1}^{N-2} \alpha_{n-i} \quad (18)$$

Expandindo a Equação 18, obtém-se:

$$Acc(n + 1) = \alpha(n + 1) + \sum_{i=0}^{N-1} \alpha_{n-i} \quad (19)$$

Unindo as Equações 17 e 19 obtém-se a relação para o acumulador de tempo (n+1) que é representada pela Equação 20. Nesta relação a cada segmento de janela o sinal de tempo futuro é somado a um novo termo de tempo atual.

$$Acc(n + 1) = \alpha(n + 1) + Acc(n) \quad (20)$$

Devido ao fato de a FPGA utilizada não possuir DSP, os cálculos de multiplicação e divisão precisaram ser implementados através de operações matemáticas básicas como adição e subtração. A operação de multiplicação foi implementada através do algoritmo de somas sucessivas enquanto que a operação de divisão foi implementada através do algoritmo de subtrações sucessivas.

A Figura 18 apresenta o diagrama de blocos para a extração da potência do sinal, a característica extraída foi armazenada em um bloco de memória com 10 bits de endereços e 32 bits de largura de dados. Os cálculos foram realizados através de um bloco de memória RAM em conjunto com registradores para acumular o valor temporário da soma recursiva.

Na Figura 19 é possível observar o diagrama de blocos para o cálculo do valor médio absoluto, que é um bloco mais simples pois não envolve multiplicações e divisões. Este bloco foi desenvolvido utilizando um bloco de memória RAM e acumuladores apenas. Para armazenar o resultado foi utilizada uma RAM de 10 bits de endereço com 16 bits de largura de dados.

Para calcular o valor RMS foi implementado um bloco semelhante ao utilizado para o cálculo da potência, porém acrescentando o cálculo da raiz quadrada que foi implementado através do método de *Newton-Raphson*. O valor obtido foi armazenado em um bloco de memória RAM com 10 bits de endereços e 32 bits de largura de dados. A característica associada ao comprimento de onda foi implementada com o auxílio de um atraso *delta* para representar o termo x_i em conjunto com um subtrator e um somador, ambos de 16 bits. O valor calculado do comprimento de onda é armazenado em um bloco de memória RAM com 10 bits de endereços e largura de dados de 16 bits, estes blocos são apresentados na Figura 20.

Para armazenar as características calculadas, foram utilizados quatro bancos de memória RAM em que cada banco armazena uma característica para cada canal. Nesta disposição, todas as árvores possam ser alimentadas no mesmo ciclo de *clock*, eliminando possíveis gargalos de comunicação. O mapa de memórias criado para o sistema proposto

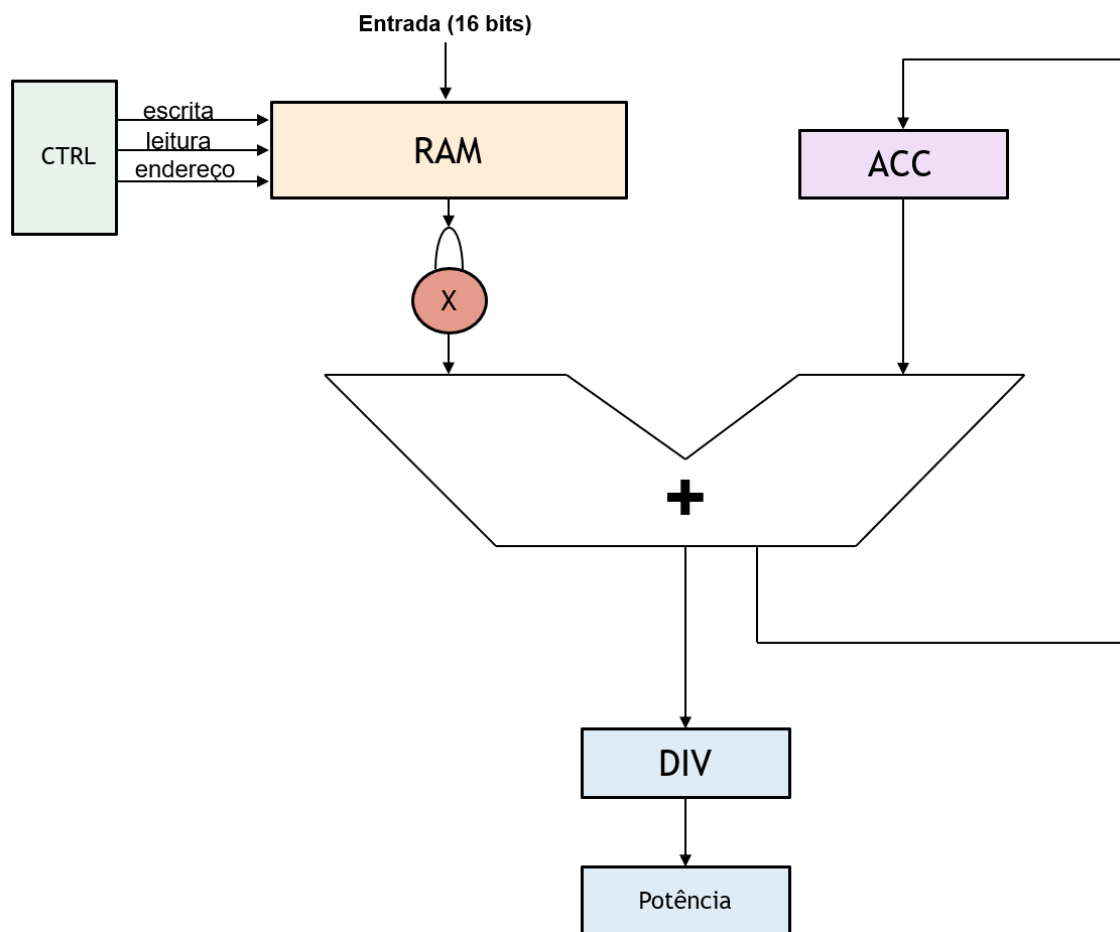


Figura 18: Diagrama de blocos para extração da característica "Potência".

Fonte: Autor.

é apresentado na Figura 21. Cada árvore é conectada a quatro bancos de memória em que cada banco será conectado em diferentes profundidades na árvore de modo que a consulta de cada árvore será sob atributos diferentes.

Após o cálculo e o armazenamento das características, as mesmas são direcionadas para o bloco de classificação do sistema.

3.2.2 Classificador *Random Forest* em VHDL

Árvores de Decisão compreendem basicamente a tomada de decisões com base em parâmetros pré-definidos e com isto decidir se a árvore seguirá o ramo da esquerda ou o ramo da direita. A implementação desta tomada de decisões é implementada através de comparadores onde cada entrada é comparada com o valor de limiar e a partir de então é decidido qual galho será seguido pela árvore. *Random Forests* seguem exatamente o mesmo funcionamento, porém com várias árvores realizando este processo simultaneamente.

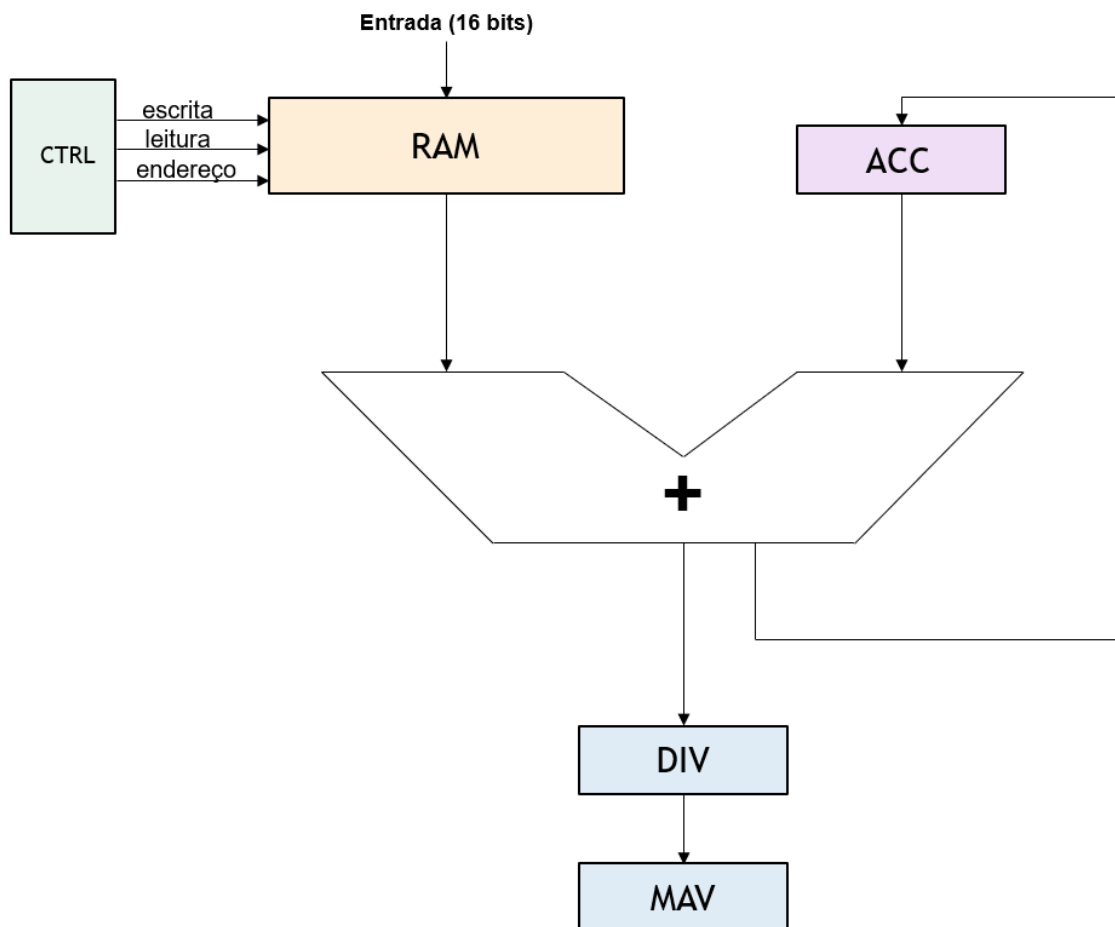


Figura 19: Diagrama de blocos para extração do valor médio absoluto (MAV).

Fonte: Autor.

O processo de classificação em RF consiste em combinar o resultado da classificação realizada por cada árvore individualmente e encaminhado para o sistema de votação, que resultará no movimento predito. Na Figura 22 é ilustrada a representação básica de uma RF que é composta por 'n' árvores de decisão em que o resultado de cada árvore é aglutinado para votação do valor predito.

Na Figura 23 é representada a nível de descrição de hardware a RF exibida na Figura 22, os blocos de comparação são representados por multiplexadores que determinam o ramo da árvore que será seguido.

Computacionalmente é possível criar RFs com centenas de árvores com a profundidade máxima variável sendo configuradas de forma a atender a necessidade do problema à ser classificado. Em VHDL o processo de criação das árvores segue o mesmo princípio, neste trabalho as RFs foram criadas com 8 árvores e 4 nós de profundidade cada uma, esta definição foi feita com base em testes preliminares realizados em ambiente computacional. Nestes testes foram realizadas classificações variando o número de árvores e a profundidade máxima de modo a se obter a melhor relação taxa de acerto x tempo de

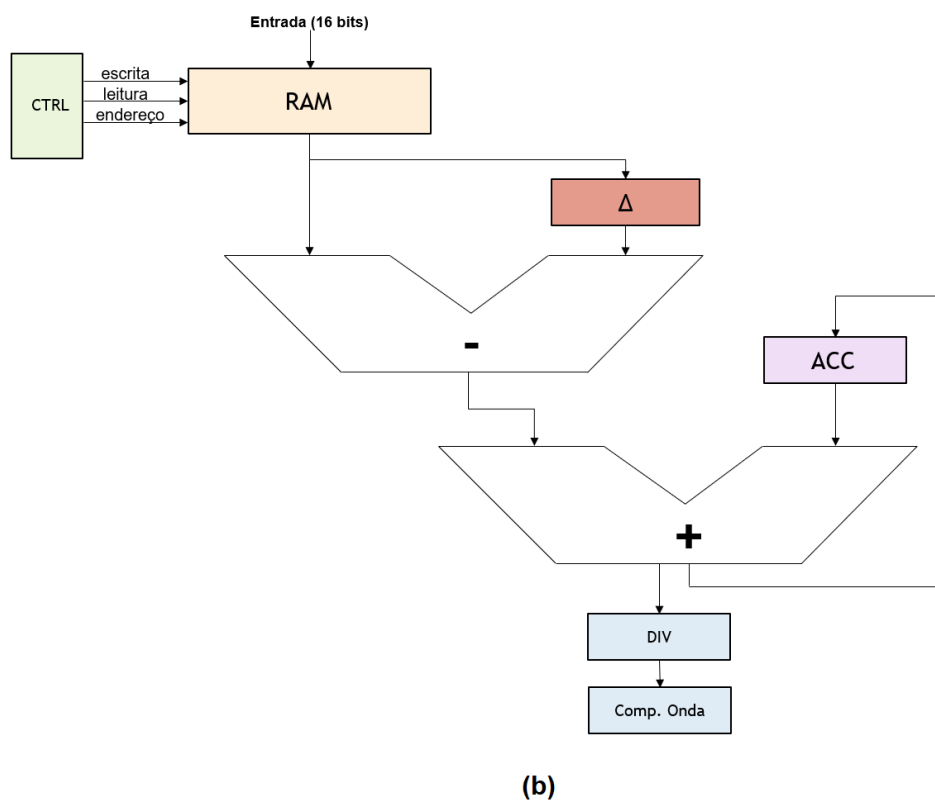
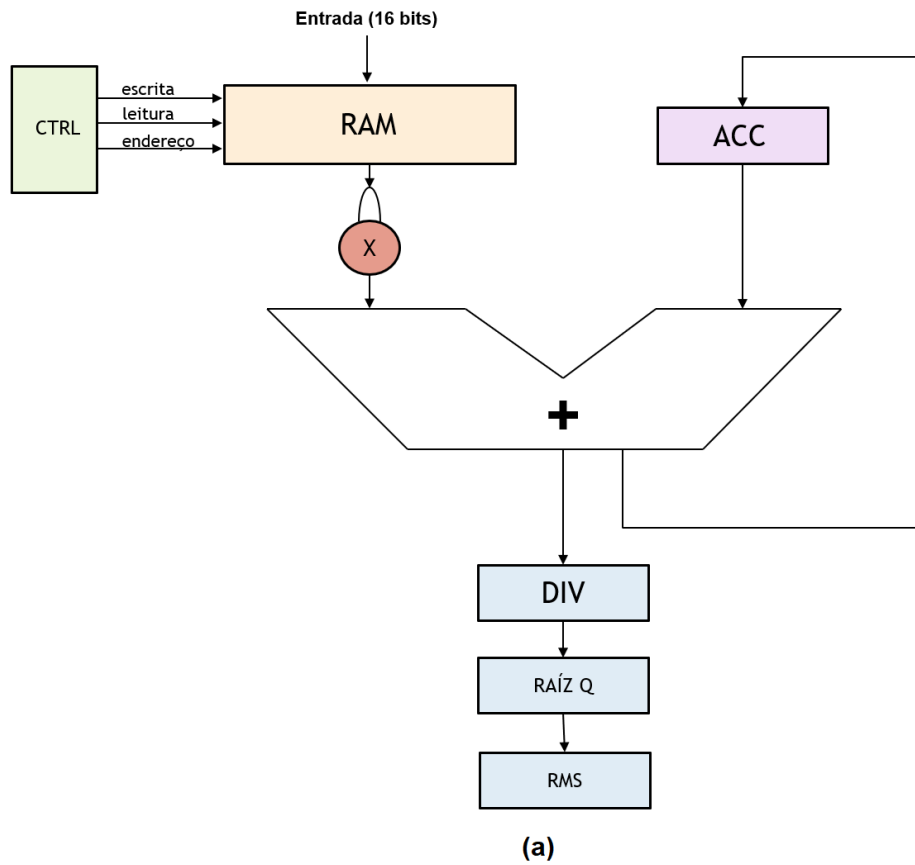


Figura 20: Diagrama de blocos para extração das características:
 (a) Valor RMS. (b) Comprimento de onda (WL).

Fonte: Autor.

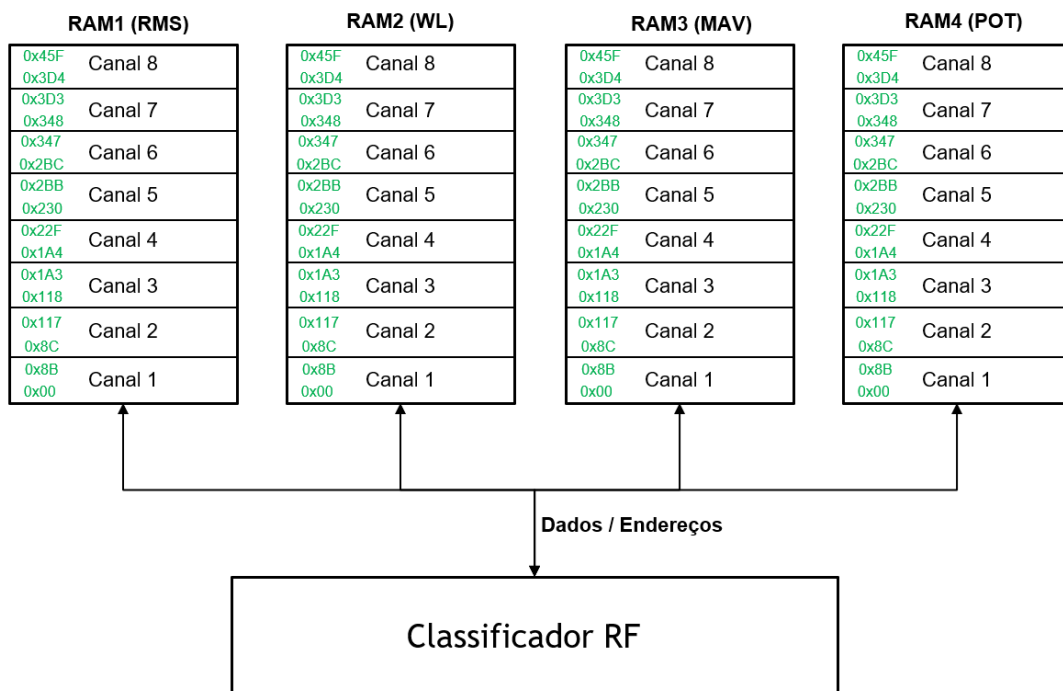


Figura 21: Mapa de memória para alocação das características calculadas.

Fonte: Autor.

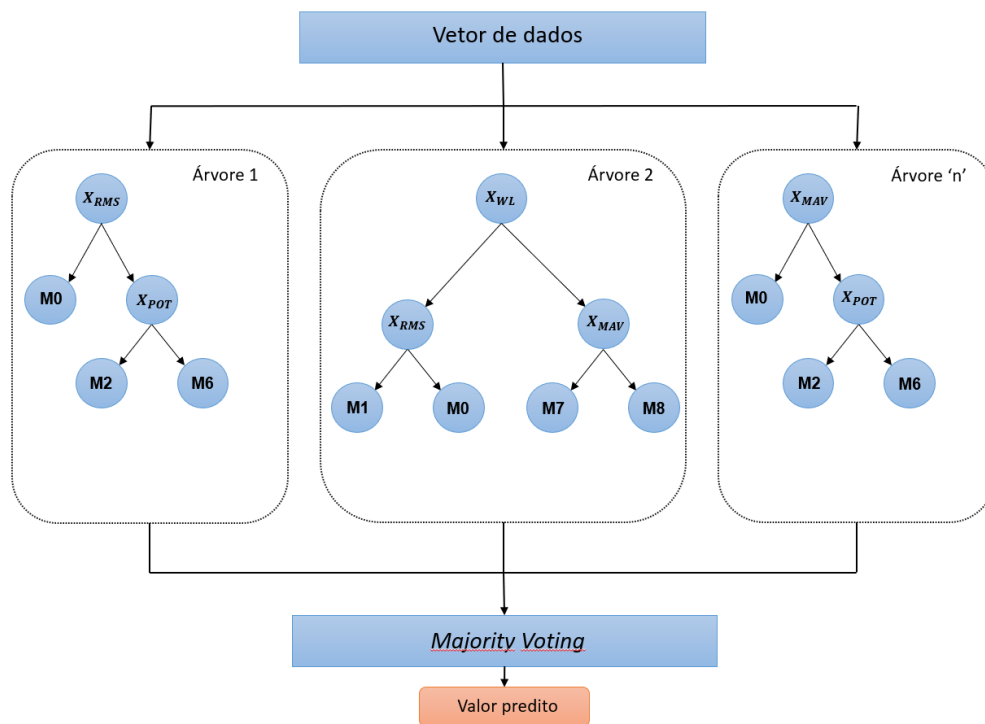


Figura 22: Representação da arquitetura de uma *Random Forest*.

Fonte: Autor.

treinamento.

O valor de limiar é o parâmetro que será utilizado pela RF para determinar qual caminho da árvore será percorrido. De acordo com (FINDIK *et al.*, 2020), este parâmetro

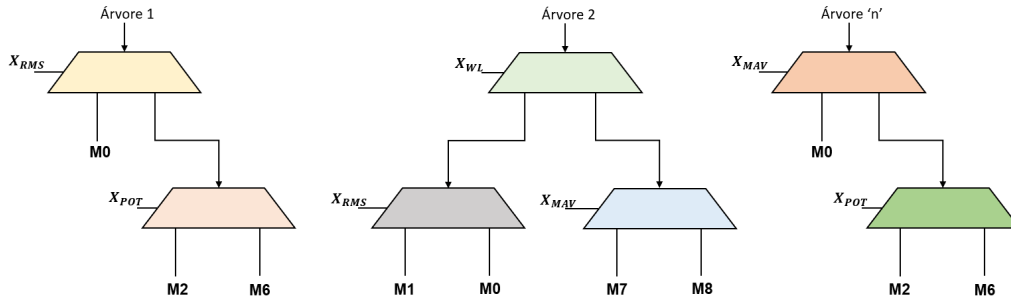


Figura 23: Representação da descrição de hardware de uma árvore de decisão.

Fonte: Adaptado de (JINGJUI *et al.*, 2018).

pode ser calculado através do Índice de Gini, determinado pela Equação 21. Este índice mede a impureza do nó e a sua determinação consome menos recursos de hardware.

$$G_i = 1 - \sum_{k=1}^n p_{i,k}^2 \quad (21)$$

Onde:

$$p_{i,k} = \frac{\text{valor da amostra}}{\text{quantidade de amostras}} \quad (22)$$

Cada árvore carrega um vetor de dados de endereços que contém a informação de teste e qual o endereço do caminho seguinte a ser executado. Na Figura 24 é exibida a estrutura de uma das 'n' árvores que compõem a RF. Esta topologia foi adotada para todas as árvores que constituem o classificador.

Todas as árvores possuem um bloco de memória RAM dedicado que foi segmentado em estágios e estes blocos são acessados na medida em que a árvore de decisão é percorrida. Esta topologia permite que as RAMs sejam acessadas simultaneamente e possibilita que as informações sejam transmitidas em *pipeline*.

Cada nó carrega a informação se este é uma folha ou uma ramificação, pois cada vetor carrega uma informação pertinente ao próximo estágio de processamento. Nós que constituem uma ramificação precisam transportar para o nó seguinte o valor que será comparado e para qual endereço a árvore seguirá, caso seja uma folha a informação que deve ser transmitida é o *label* de identificação do movimento realizado para o sistema de votação. Na Figura 25 é ilustrada a estrutura dos dois tipo de nó e a informação que cada um carrega durante a execução de cada árvore.

O sistema de votação foi implementado através de lógica combinacional e um elemento de memória, visto que para a definição do resultado é realizada uma comparação aritmética simples entre os valores que mais vezes foram escolhidos pelo classificador como movimento predito. Caso o sistema não chegue a um valor de resposta, como dois movimentos identificados a mesma quantidade de vezes o sistema proposto enviará via

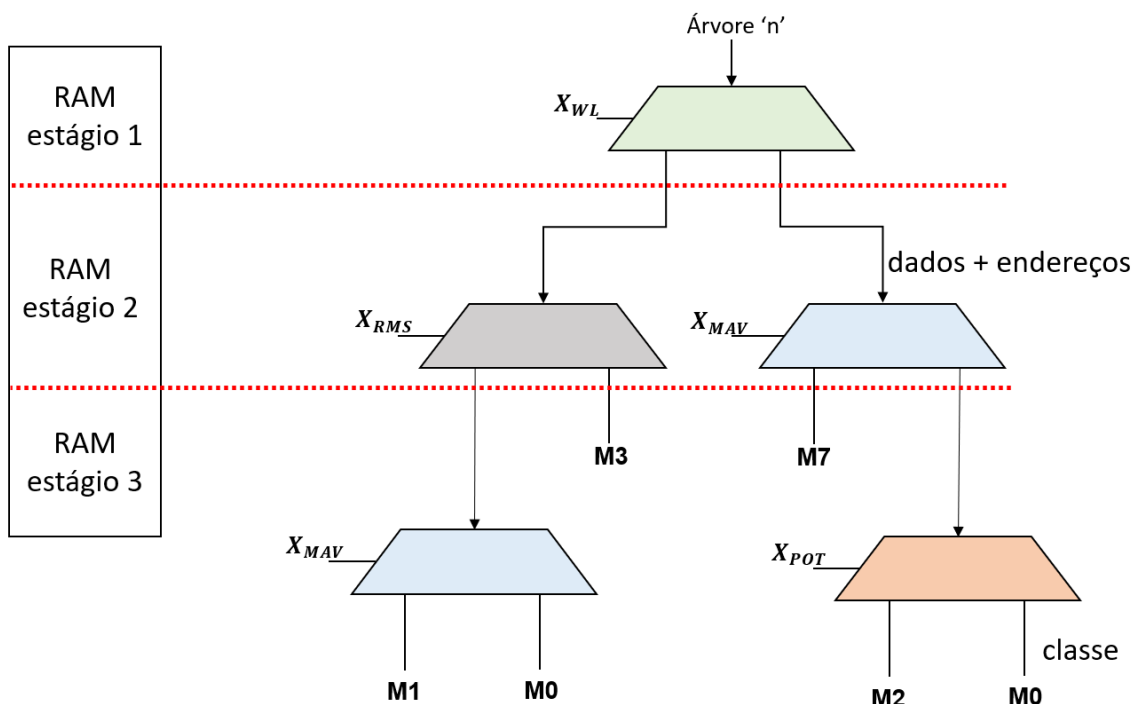


Figura 24: Estrutura de uma árvore que compõem a *Random Forest*.

Fonte: Autor.

Tipo de nó Ramo	Característica	Valor de comparação	Endereço nó esquerda	Endereço nó direita
Tipo de nó Folha	Identificador do movimento (classe)			

Figura 25: Estrutura da ramificação das árvores de decisão.

Fonte: Autor.

comunicação serial uma mensagem informando que a classificação deve ser realizada novamente.

3.3 PROCEDIMENTO PARA VALIDAÇÃO DO CIRCUITO DE AQUISIÇÃO

A análise do circuito de aquisição foi dividida em três partes:

- Circuito de alimentação;
- Relação sinal/ruído;
- Validação dos filtros

Na Figura 26 é ilustrado o *setup* utilizado para validação dos filtros e relação sinal/ruído do circuito de aquisição.




Figura 26: Procedimento experimental para validação do circuito de aquisição.

Fonte: Autor.

Na Tabela 5 são referenciados os equipamentos utilizados durante os testes:

Tabela 5: *Setup* de teste.

Item	Equipamento	Fabricante	Modelo
1	Protótipo desenvolvido	-	-
2	Fonte de tensão	BK-Precision	19028
3	Osciloscópio digital	Keysight	DSOX1192G
4	Gerador de funções	Tektronix	AFG3102C

3.3.1 Autonomia do sistema

Os quatro blocos que compõem o circuito de alimentação são exibidos na Figura 27, a validação deste circuito foi realizada monitorando a estabilidade das saídas de 3V3 durante a descarga da bateria que mantém o circuito energizado. Os 8 canais de entrada foram alimentados e a FPGA configurada para operar em modo de classificação em ciclos repetidos, este cenário de teste foi utilizado devido ao fato de ser o modo de funcionamento mais crítico do sistema.

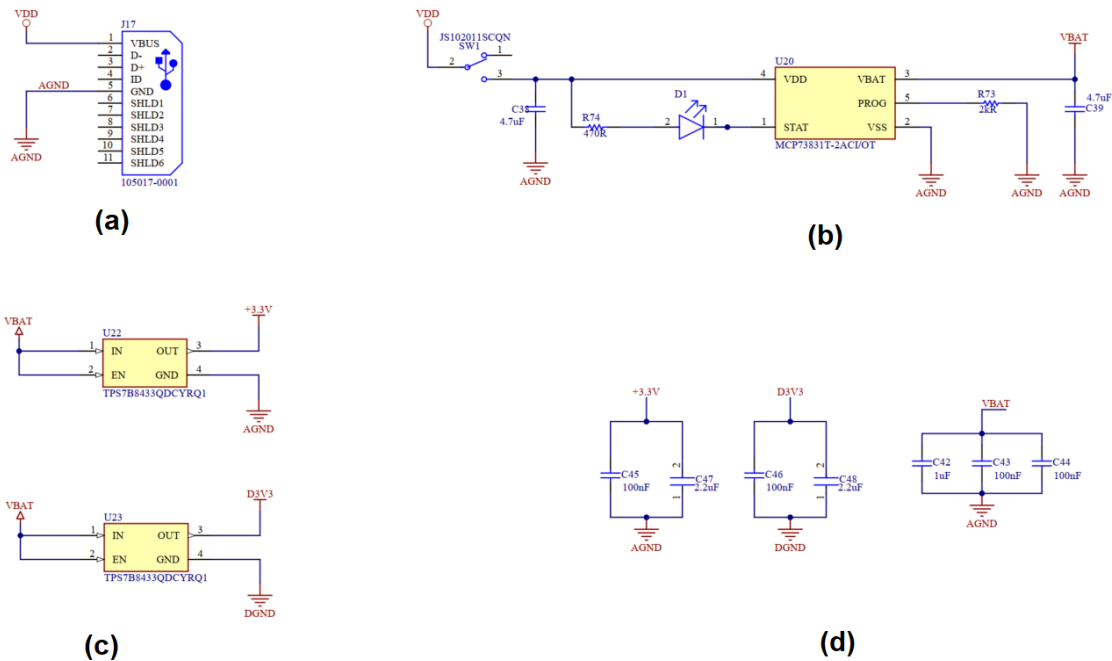


Figura 27: Circuito de alimentação do protótipo desenvolvido.

- (a) Conector mini-USB para entrada de alimentação - (b) Circuito carregador de bateria
 (c) Saídas de 3V3 - (d) Capacitores de desacoplamento.

Fonte: Autor.

3.3.2 Relação sinal/ruído

A relação sinal/ruído expressa a diferença entre o sinal recebido e o nível de ruído intrínseco do circuito sem excitação, é uma forma de representar a qualidade do circuito eletrônico. Matematicamente a SNR é determinada pela Equação 23, em que o termo P_{sinal}^2 representa a potência de um sinal conhecido aplicado na entrada do circuito e o termo $P_{ruído}^2$ representa a potência do sinal no mesmo circuito, porém, quando sua entrada está conectada ao plano de terra.

$$SNR_{dB} = 10 \log_{10} \left(\frac{P_{sinal}^2}{P_{ruído}^2} \right) \quad (23)$$

Cada canal foi excitado com um sinal de $10mV_{dc}$ na entrada e sua potência foi determinada através da relação $P = V * i$ e posteriormente a entrada do canal foi conectada ao plano de terra e a mesma medida foi realizada novamente. Na Figura 28 é ilustrado o diagrama esquemático de um dos oito canais de aquisição, onde a entrada do canal representada pela coordenada CH1P e a saída representada pelo ponto CH1ADC.

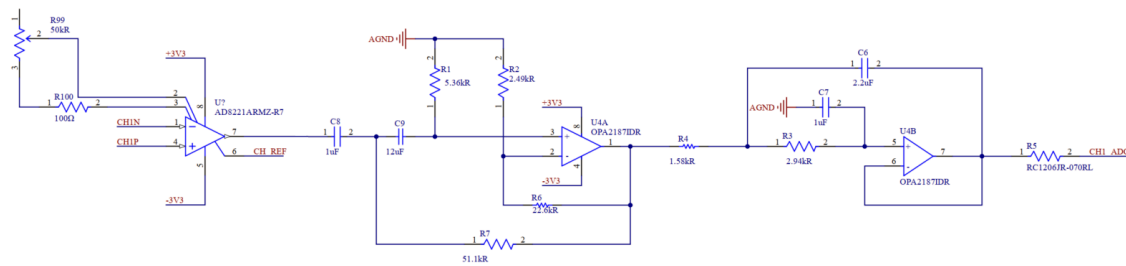


Figura 28: Diagrama esquemático de um canal de aquisição.

Fonte: Autor.

3.3.3 Validação dos filtros

A validação dos filtros foi realizada através do procedimento de varredura em frequências também conhecido como *sweep* de frequências. Isto consiste em gerar um sinal contínuo cuja frequência varia logaritmicamente com o tempo, fornecendo assim a gama completa de frequências de teste entre as frequências de passagem e de corte determinadas pelo filtro. O gerador de funções, responsável por gerar o sinal com frequência variável é conectado na entrada do canal e o osciloscópio é conectado na saída do canal, conforme apresentado na Figura 29.




Figura 29: Esquemático para varredura em frequência para validação dos filtros ativos.

Fonte: Autor.

O gerador de funções foi configurado com a seguinte parametrização:

- Tensão de saída: $1V_{pp}$;
- Frequência inicial: 5Hz;
- Frequência final: 1kHz;
- Variação de frequência: Logarítmica.

O sinal fornecido pelo gerador de funções é ilustrado na Figura 30

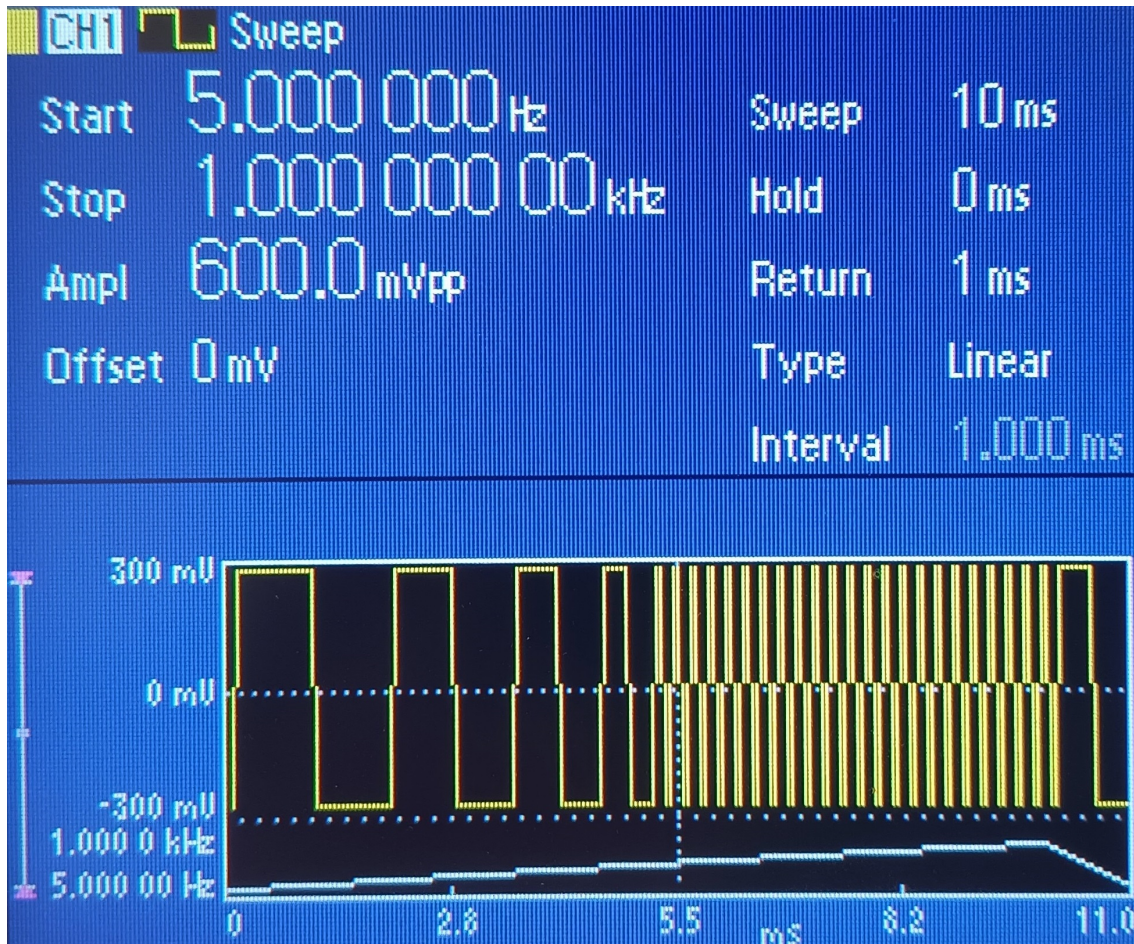


Figura 30: Varredura realizada entre as frequências de passagem e corte para validação dos filtros ativos.

Fonte: Autor.

3.4 PROCEDIMENTO PARA VALIDAÇÃO DO CLASSIFICADOR

3.4.1 Avaliação do desempenho do sistema

O experimento para avaliação do sistema proposto foi realizado com o auxílio das bases de dados Flor de Iris e Ninapro (ATZORI et al., 2014). A base NinaPRO contém sinais mioelétricos de 40 sujeitos não amputados capturados durante a execução de 17 movimentos básicos de dedos e pulso. Os indivíduos não amputados são homens e mulheres com idade entre 23 e 45 anos com IMC entre 18 e $31,5 \text{ kg/m}^2$, um indício de que a bioimpedância destes indivíduos é um fator relevante para a aquisição dos sinais. Destros e canhotos executaram os movimentos utilizando a mão direita, na Tabela 6 é apresentada a relação dos usuários que foram utilizados na avaliação do sistema.

Os ensaios consistiam em os sujeitos reproduzirem os movimentos apresentados em

Tabela 6: Descrição dos indivíduos não amputados da base NinaPRO.

Indivíduo	Lateralidade	Sexo	Idade	Altura [cm]	Peso [kg]
1	Destro	Masculino	29	187	75
2	Destro	Masculino	29	183	75
3	Destro	Masculino	31	174	69
4	Canhoto	Feminino	30	154	50
5	Destro	Masculino	25	170	70
6	Destro	Masculino	35	172	79
7	Destro	Masculino	27	187	92
8	Destro	Masculino	45	173	73
9	Destro	Masculino	23	172	63
10	Destro	Masculino	34	173	84
11	Destro	Feminino	32	150	54
12	Destro	Masculino	29	184	90
13	Canhoto	Masculino	30	182	70

uma tela de computador com 12 eletrodos ativos *Delsys Trigno* posicionados no antebraço, no bíceps e no tríceps. Cada movimento tinha duração de 5 segundos e era executado seis vezes por cada indivíduo com um período de repouso de 3 segundos entre cada repetição. Durante a execução, os sinais mioelétricos foram capturados por um eletromiógrafo utilizando eletrodos de superfície com taxa de amostragem de 2 kHz e 16 bits de resolução.

Além da base DB2 do repositório NinaPRO, foi também utilizado o *dataset* Flor de Iris que é um conjunto de dados amplamente conhecido e discutido em diversos trabalhos. Este conjunto está disponível no repositório *UCI Machine Learning Repository*, criado em 1987 e que atualmente dispõe de mais de 600 *datasets* para acesso gratuito. A Tabela 7 apresenta um breve resumo das bases utilizadas.

Tabela 7: Características das bases de dados utilizadas.

Base de dados	Total de amostras	Total de atributos
Flor de Íris	450	5
NinaPRO-DB2	17093825	9

As características pertinentes a cada *dataset* foram extraídas através de um *script* em Python e salvas em um arquivo csv que posteriormente foram enviados à FPGA através

da comunicação SPI com o ESP32. O sistema realiza a classificação do conjunto de dados e retorna o valor predito via comunicação SPI ao ESP32 que exibe o resultado encontrado. Na Figura 31 é ilustrado o diagrama de conexões utilizados para a validação do classificador.

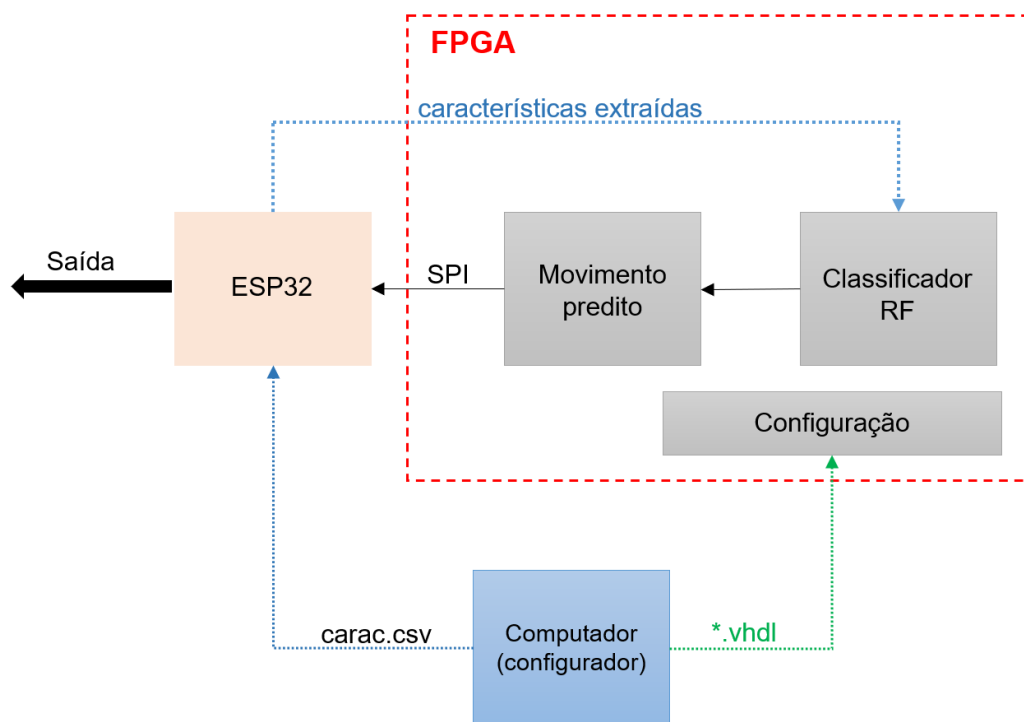


Figura 31: Configuração do sistema utilizada para validar o classificador embarcado.

Fonte: Autor.

Na Figura 32 são exibidos os 7 movimentos da base DB2 do repositório NinaPRO utilizados para a validação do classificador durante o protocolo de ensaios. Estes movimentos foram escolhidos com base no repositório Nina-PRO DB2 que ao todo contém 17 movimentos de usuários não amputados.

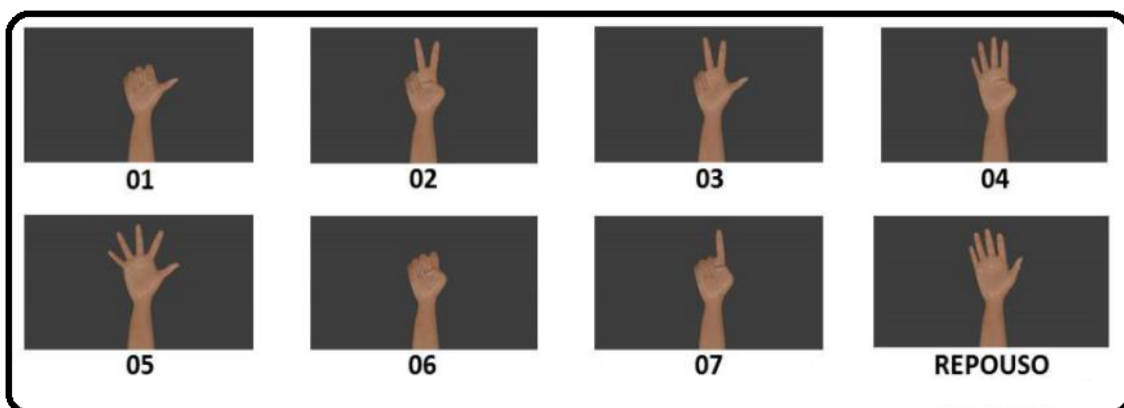


Figura 32: Movimentos realizados pelo indivíduo durante o protocolo experimental.

Fonte: Autor.

3.4.2 Protocolo experimental para validação do sistema completo

De acordo com a literatura clássica, a aquisição de sinais mioelétricos pode ser realizada sob duas diferentes configurações: monopolar ou bipolar. Neste trabalho foi abordada a configuração bipolar em que são utilizados três eletrodos sendo um eletrodo utilizado como referência e os outros dois nas entradas diferenciais. De acordo com (BASMAJIAN & DE LUCA, 1985) os eletrodos diferenciais devem ser posicionados na direção das fibras musculares, sendo as áreas marginais dos músculos menos adequadas devido ao reduzido número de MUAPs nestas regiões.

Idealmente, para a melhor aquisição dos sinais mioelétricos os eletrodos devem ser posicionados o mais próximo possível do músculo responsável pelo movimento desejado. Na Figura 33 é ilustrada a musculatura do braço e antebraço e a fixação de cada eletrodo foi realizada conforme a Tabela 8.




Figura 33: Musculatura do segmento mão-braço do corpo humano.


Fonte: Adaptado de (TORTORA, 2017).

Tabela 8: Posicionamento dos 8 pares de eletrodos para a coleta de sinais sEMG.


Canal	Músculo	Função
CH1	Extensor dos dedos	Estende os dedos
CH2	Flexor radial do carpo	Flete e abduz a mão
CH3	Palmar longo	Flexiona a mão
CH4	Flexor ulnar do carpo	Flete e aduz a mão
CH5	Extensor ulnar do carpo	Aduz a mão
CH6	Flexor superficial dos dedos	Estende as falanges
CH7	Abdutor longo do polegar	Estende e abduz o polegar
CH8	Braquiorradial	Flete o antebraço

Na Figura 34 é possível observar os eletrodos fixados no braço do indivíduo para a execução do protocolo experimental. Porém, alguns cuidados foram tomados antes de iniciar a coleta de dados:

- Limpeza da pele onde os eletrodos ficarão conectados;
- Raspagem dos pêlos do braço para ampliar a área de contato do eletrodo;
- Os cabos foram posicionados de modo a não atrapalhar os movimentos e não se movimentem durante a aquisição.



(a) Eletrodos fixados na parte posterior do braço.



(b) Eletrodos fixados na parte anterior do braço.

Figura 34: Preparação para o protocolo experimental de ensaios.

Fonte: Autor

Com os eletrodos fixados conforme ilustrado na Figura 34, o indivíduo de teste realizou a coleta de dados seguindo a rotina ilustrada no fluxograma da Figura 35. A aquisição é iniciada pela rotina de calibração, esta rotina é realizada a cada nova coleta de modo a informar o sistema qual é a posição de repouso.

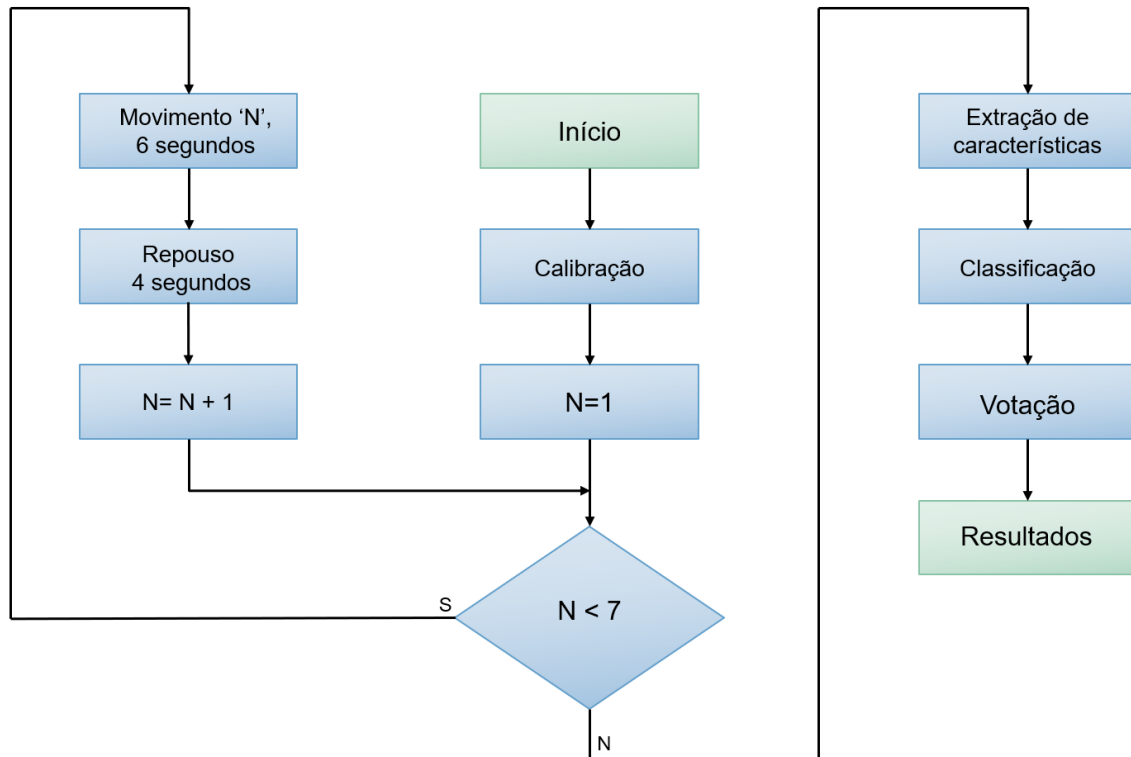


Figura 35: Procedimento experimental para coleta de dados.

Fonte: Autor.

A rotina de calibração abordada anteriormente pode ser observada com mais detalhes na Figura 36. É possível observar que o movimento de repouso é realizado repetidas vezes alternando com o movimento de flexão da mão.

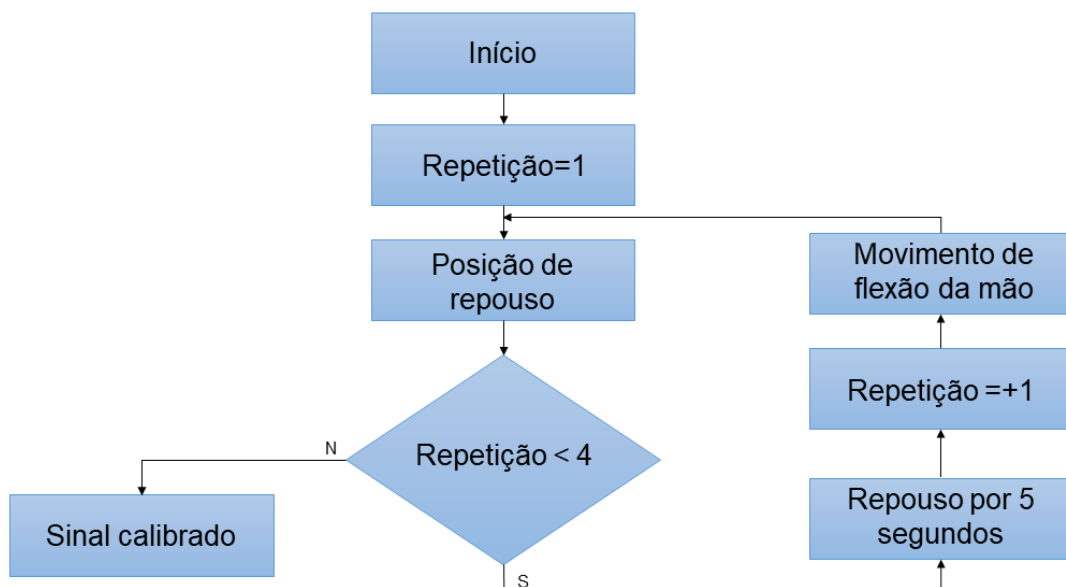



Figura 36: Rotina de calibração para determinação da posição de repouso do sistema proposto.

Fonte: Autor.

Na Figura 37 é possível observar o aparato experimental com os 8 pares diferenciais de eletrodos fixados no braço do indivíduo para a aquisição dos sinais mioelétricos através do protocolo de ensaios.



(a) Sistema de aquisição conectado aos eletrodos.



(b) Indivíduo realizando o protocolo experimental.

Figura 37: Execução do protocolo experimental de ensaios.

Fonte: Autor

4 RESULTADOS & DISCUSSÃO

A validação do protótipo desenvolvido foi dividida em duas etapas: validação do circuito de aquisição que consitui o bloco analógico e validação do classificador, que consitui o bloco controlado pela FPGA.

4.1 VALIDAÇÃO DO CIRCUITO DE AQUISIÇÃO

A autonomia do sistema é de aproximadamente 130 minutos considerando o funcionamento dos oito canais, até que o circuito de 3V3 não suportasse mais o funcionamento do circuito de condicionamento. Na Figura 9 foi plotado o gráfico $V \times t$ durante os testes, em azul é destacada a tensão de saída da bateria e em laranja é representada a saída do circuito de 3V3.




Figura 38: Curva $V \times t$ os circuitos: Vbat em azul; +3V3 em laranja.

Fonte: Autor.

Na Figura 39 é ilustrada a medição realizada com o osciloscópio quando a entrada do canal 1 está conectada ao terra, neste momento foi medido $664\mu\text{V}$. Os resultados obtidos estão de acordo com a literatura clássica em que a SNR para que o circuito possua o funcionamento adequado deve ser superior a 30dB (NILSON & RIEDEL, 2009). As SNRs do demais canais são informadas na Tabela 9.

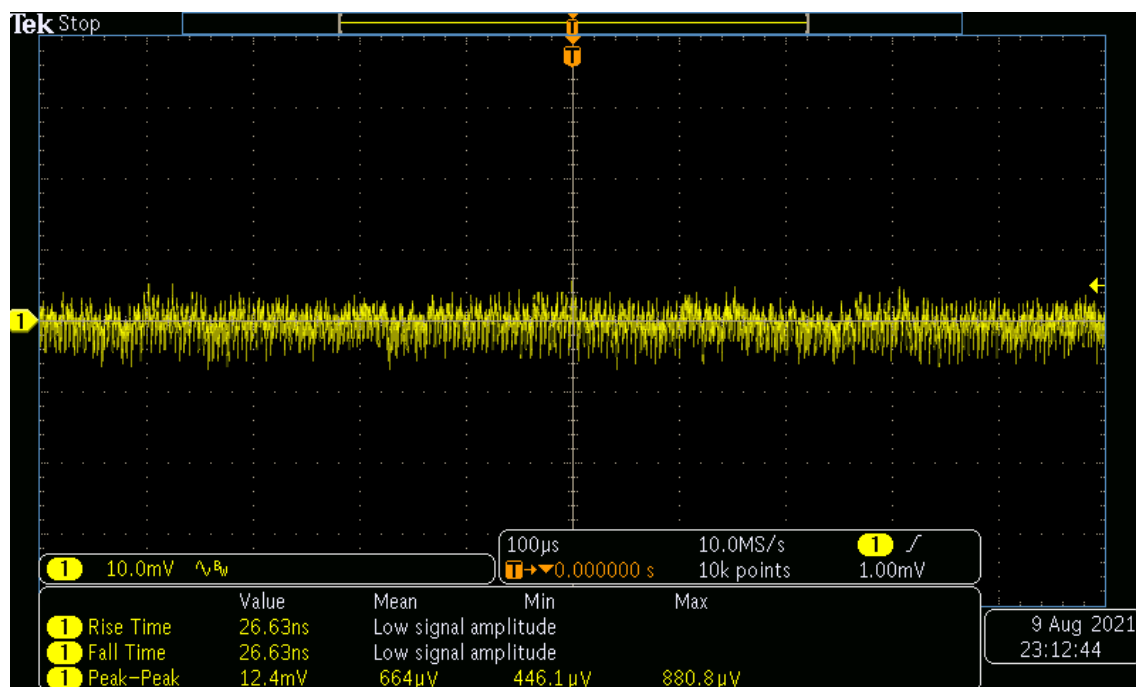


Figura 39: Medição realizada para determinação da SNR do canal 1.

Fonte: Autor.

Tabela 9: SNR obtida em cada canal.

Canal	SNR [dB]	Canal	SNR [dB]
CH_1	47	CH_5	41,2
CH_2	42	CH_6	48,3
CH_3	48,5	CH_7	48,1
CH_4	38,7	CH_8	48,1

Nas Figuras 40 e 41 são ilustradas as respostas em frequência dos canais 1 e 2 respectivamente. Pode-se observar que não há atenuação de sinal entre as frequências de 5Hz e 200Hz e que a partir de 500Hz ocorre uma grande atenuação do sinal, na ordem de -40dB por década. As medições realizadas na saída do circuito estão de acordo com filtro projetado, a resposta do filtro para a medição realizada no canal 1 pode ser observada na Figura 30. As medições para os demais canais são referenciadas no Apêndice A.3.




Figura 40: Resposta em frequência do conjunto de filtros utilizados no canal 1.

Fonte: Autor.




Figura 41: Resposta em frequência do conjunto de filtros utilizados no canal 2.

Fonte: Autor.

4.2 VALIDAÇÃO DO CLASSIFICADOR

Durante a classificação da base Flor-de-Iris, o classificador desenvolvido obteve uma acurácia de 83,10% no conjunto de teste. Este resultado vai ao encontro a resultados encontrados em outros trabalhos publicados. Dentre estes trabalhos pode-se destacar o resultado obtido por (ABDOLRAHIM & GAUDET, 2022) que obtiveram uma acurácia de 86% sob a base Flor de Íris utilizando um classificador RF embarcado em uma FPGA Arria 10 da Altera. Os resultados para o conjunto de teste podem ser observados na Figura 42.




Figura 42: Taxa de acerto do conjunto de teste do classificador RF embarcado para a base Flor de Íris. Em azul: classificador desenvolvido em Python; Em verde: classificador apresentado neste trabalho; Em laranja: classificador apresentado por (Abdolrahim & Gaudet).

Fonte: Autor.

O desempenho inferior apresentado em relação ao classificador em Python já era previsto devido ao fato de haver uma disponibilidade maior de recursos computacionais no ambiente python em relação ao sistema embarcado. E quando comparadas apenas os classificadores embarcados nas FPGAs, era esperado que houvessem pequenas diferenças nas taxas de acerto devido a diferença de arquitetura pois a FPGA utilizada neste trabalho não possui blocos de DSP.

Após a validação inicial do classificador com um *dataset* equilibrado, os testes foram repetidos com dados de eletromiografia obtidas do repositório NinaPRO para avaliar se o

classificador atingiria métricas de classificação adequadas para sua utilização. Na Figura 43 é apresentada a taxa de acurácia para cada indivíduo analisado. Pode-se observar que o sistema obteve uma acurácia média de 81,9% no conjunto de teste de indivíduos não amputados. Esta taxa de acerto possui diferentes causas, como o fato de não ser uma base perfeitamente balanceada, o posicionamento dos eletrodos durante as aquisições ou ainda ao fato de o extrator de características utilizar cálculos aproximados para a determinação das operações como multiplicação e divisão.




Figura 43: Taxa de acurácia para os 13 indivíduos não amputados da base DB2 do repositório NinaPRO.

Fonte: Autor.

Na Tabela 10 é apresentada de maneira estratificada a acurácia de cada indivíduo analisado.

Tabela 10: Taxa de acurácia estratificada por indivíduo.

Indivíduo	Acurácia [%]	Indivíduo	Acurácia [%]	Indivíduo	Acurácia [%]
Indivíduo 1	83,12	Indivíduo 6	84,29	Indivíduo 11	78,87
Indivíduo 2	81,69	Indivíduo 7	82,61	Indivíduo 12	82,35
Indivíduo 3	82,19	Indivíduo 8	81,94	Indivíduo 13	77,78
Indivíduo 4	81,94	Indivíduo 9	81,82	-	-
Indivíduo 5	84,29	Indivíduo 10	82,81	-	-

O adequado posicionamento e fixação dos eletrodos é de grande importância para a taxa de acertos do classificador, influenciando na correta identificação dos movimentos. Na Figura 44 é apresentada a taxa de acurácia para cada movimento de todos os 13 indivíduos analisados. É possível observar que alguns movimentos apresentaram uma taxa de acertos menor. Neste cenário o movimento 4 foi o que apresentou na média a menor taxa de acerto com 77% de acurácia sobre o conjunto de testes, enquanto que os movimentos 3 e 6 obtiveram em média uma taxa de acerto de próxima a 88% no conjunto de teste.




Figura 44: Taxa de acurácia em função do movimento para os 13 indivíduos não amputados da base DB2 do repositório NinaPRO.

Fonte: Autor.

4.2.1 Análise do indivíduo com pior desempenho

Na Figura 45 é apresentada a acurácia em função do movimento para o usuário 13, em que é possível observar que o movimento 4 possui a menor taxa de acerto com 69% de acurácia no conjunto de teste. Observando a matriz de confusão apresentada na Figura 46 nota-se que o classificador se confundiu majoritariamente entre os movimentos 4 e 5, que são anatomicamente semelhantes (4 dedos abertos e mão inteira aberta). Isto evidencia que o classificador implementado não conseguiu decidir adequadamente entre alguns movimentos.

Efeito semelhante foi identificado no indivíduo 11 em que o movimento 4 apresentou uma taxa de acerto de 75% e o movimento 5 obteve uma taxa de acerto de 73% ficando abaixo dos demais movimentos realizados pelo mesmo usuário. Na Figura 47 é apresentada a matriz de confusão do conjunto de teste para o usuário 11.




Figura 45: Curva de acurácia em função do movimento para o indivíduo 13 da base NinaPRO.

Fonte: Autor.

Movimento real	1	7	0	0	0	0	0	
	2	0	8	0	0	0	1	
	3	0	1	9	1	0	0	
	4	0	0	0	9	3	0	
	5	0	0	1	3	8	0	
	6	2	0	0	0	0	8	
	7	0	1	1	0	0	2	
		1	2	3	4	5	6	7
		Movimento predito						

Figura 46: Matriz de confusão do indivíduo 13 da base NinaPRO.

Fonte: Autor.

Estes resultados indicam que o classificador proposto apresenta certa confusão em alguns movimentos parecidos. Uma alternativa para minimizar este efeito seria acrescentar uma nova característica ou ainda ampliar o número de árvores consultadas para formação do resultado predito.

Movimento real	1	6	1	0	0	0	0	0
	2	0	8	0	0	0	0	0
	3	1	0	9	1	0	1	0
	4	0	0	0	9	2	0	0
	5	0	0	1	2	8	0	0
	6	1	0	0	0	1	9	2
	7	0	1	0	0	0	1	7
		1	2	3	4	5	6	7
		Movimento predito						

Figura 47: Matriz de confusão do indivíduo 11 da base NinaPRO.

Fonte: Autor.

4.2.2 Análise da aquisição experimental de sinais sEMG

Na Figura 48 é apresentada a taxa de acurácia para o indivíduo de testes durante a aquisição experimental realizada com o sistema proposto onde foi obtida uma acurácia média de 73,8%. Esta taxa é inferior à acurácia média de 81,9% obtida para o repositório NinaPRO considerando os mesmos movimentos. Esta diferença pode estar relacionada a diversos fenômenos, como a não idealidade dos filtros ou ainda ao *crosstalk* entre os canais pelo fato de os testes terem sido realizados na primeira versão do protótipo em que ainda não haviam todos os planos de terra implementados na placa de circuito impresso.

A matriz de confusão exibida na Figura 49 corrobora com este fato, visto que os movimentos com a menor taxa de acerto são os movimentos 4 e 5 indicando que o classificador tende a confundir movimentos que são semelhantes. Na Tabela 11 são estratificadas as taxas de acerto por movimento, onde é possível verificar que as menores taxas de acerto são de 69% e 71% para os movimentos 4 e 5 respectivamente. Em contrapartida, movimentos que apresentam uma variação mais brusca obtiveram melhores taxas de acerto.




Figura 48: Taxa de acurácia para o indivíduo de testes durante o protocolo experimental.

Fonte: Autor.

Movimento real	1	29	4	0	1	0	1	1
	2	3	21	0	0	0	1	0
	3	2	0	18	3	3	0	3
	4	0	2	0	22	5	0	0
	5	1	0	4	5	27	0	0
	6	5	0	0	1	3	30	5
	7	0	1	3	0	0	6	28
		1	2	3	4	5	6	7
		Movimento predito						

Figura 49: Matriz de confusão do indivíduo de testes para o protocolo experimental.

Fonte: Autor.

Outro fator que deve ser considerado na redução da acurácia para o sistema proposto em comparação com a taxa obtida na seção anterior, é estrutura física do indivíduo que participou dos testes. O indivíduo possui IMC de 32,5 que é considerado elevado de acordo com a OMS que classifica como obeso qualquer indivíduo com IMC acima de

30. Um IMC elevado pode representar um valor maior de tecido adiposo, dificultando a aquisição de sinais de sEMG.

Tabela 11: Taxa de acerto por movimento para o indivíduo de teste.

Movimento	Taxa de acerto
1	73%
2	75%
3	72%
4	69%
5	71%
6	79%
7	76%

4.3 CONSUMO DE RECURSOS

Todos os blocos do sistema de classificação de sinais de sEMG em FPGA foram embarcados na plataforma XC6 da PISWORDS que contém uma FPGA Xilinx SPARTAN XC6LSX16. Portanto, a ferramenta utilizada para converter a escrita e síntese do código VHDL a Xilinx ISE-Webpack (Versão 11.0), que apresentou os percentuais de ocupação listados na Tabela 12. Esta mostra que o sistema implementado utilizou os recursos da FPGA de forma a praticamente esgotar as Lookup Tables (LUTs), que são os recursos unitários para lógica combinacional. Grande parte dos recursos de memória (Block RAM) também foram utilizados. Na Tabela 12 é apresentada a relação dos recursos que foram utilizados da FPGA disponível, pode-se observar que os recursos foram utilizados quase em sua totalidade.

Tabela 12: Recursos utilizados.

Modo de execução	Bloco	LUTs	Flip-Flops	RAM[kb]
Série	Extr. de carac.	3380 (23%)	2470 (13%)	25 (18,3%)
	Classificação	6350 (43%)	5950 (32,6%)	48 (35,3%)
Paralelo	Extr. de carac.	3380 (23%)	2470 (13%)	25 (18,3%)
	Classificação	10730 (72,7%)	9942 (54%)	83 (61%)

Na Tabela 13 é possível observar que quando o classificador é executado no modo de operação em paralelo o consumo das unidades lógicas chega a 95%. Este é um dado

importante, porém já esperado devido ao fato de a FPGA utilizada ser uma versão mais antiga disponibilizada da XILINX, visto que o protótipo apresentado busca priorizar um custo mais reduzido em detrimento da capacidade ou velocidade de processamento.

Tabela 13: Recursos totais utilizados.

Modo de execução	LUTs	Flip-Flops	RAM[kb]	P_{media} [mW]
Série	9730 (66%)	8420 (46,2%)	73 (53,6%)	58
Paralelo	14110 (95,6%)	12412 (68,1%)	108 (79,4%)	115

Na Tabela 14 são apresentados os dados referentes a uma classificação, ou seja, o tempo que o sistema necessita para executar uma classificação completa. Como esperado, a execução em paralelo apresenta uma velocidade de processamento mais elevada o que melhora o desempenho do sistema do ponto de vista do usuário. Porém, esta melhoria é acompanhada de uma elevação na demanda de recursos de hardware, visto que mais o número de operações realizadas simultaneamente é ampliado em relação a execução em série.

Tabela 14: Taxas de frequência máxima e latência do sistema proposto.

Modo de execução	Freq. Máxima [MHz]	Latência [μ s]
Série	31,769	21,397
Paralelo	46,432	13,53

Como métrica de comparação, na Figura 50 é apresentada uma simulação de um sistema semelhante de classificação porém embarcado em um microprocessador ATMega328P. Nesta simulação foi medido o tempo necessário para gerar uma classificação. Esta medição foi realizada através de *flags* que indicavam o tempo de início e fim do processo de classificação. Pode-se observar que para sistemas de pequeno porte, seja justificado o uso de microprocessadores em função de seu custo reduzido em comparação a FPGAs e SoCs. Porém na medida que a quantidade de canais é ampliada, o desempenho do sistema microprocessado sofre uma degradação de desempenho de maneira muito mais acentuada em relação ao sistema embarcado em FPGA.

Esta diferença de desempenho é justificada em função da característica construtiva de cada dispositivo. Visto que microprocessadores executam todas suas tarefas em série enquanto que as FPGAs se valem de seu paralelismo, impactando em taxas de desempenho superiores para aplicações com um maior número de canais. Este cenário implica dizer que o uso de microprocessadores para sistemas baseados em eletromiografia de alta den-

tidade apresentará um desempenho consideravelmente inferior se comparado a sistemas embarcados em FPGA.

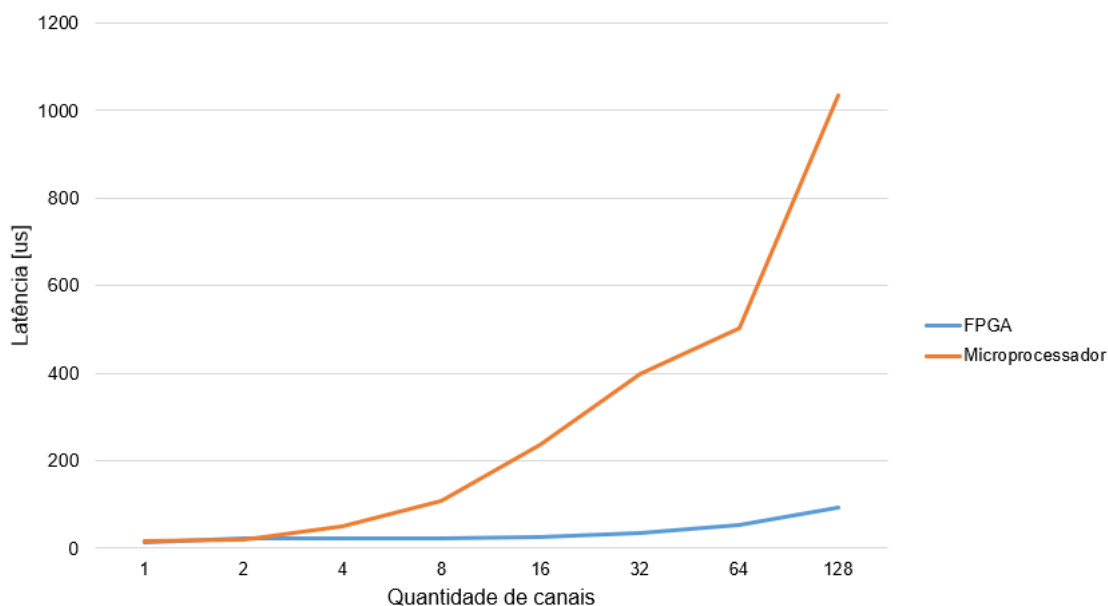


Figura 50: Tempo de latência necessário para realizar uma classificação em função da quantidade de canais. Em azul: FPGA. Em laranja: Microprocessador ATmega328P.

Fonte: Autor.

Uma alternativa interessante seria o uso de chips integrados, comumente chamados de SoC's onde no mesmo encapsulamento existe um microprocessador em conjunto com a FPGA. Com isto, os processos mais custosos sob o ponto de vista de hardware enquanto os processos que envolvam comunicação ou outras tarefas podem ser executados pelo microprocessador.

4.4 COMPARAÇÕES COM OUTROS TRABALHOS NA ÁREA

Não existem muitos trabalhos publicados em que foi embarcada uma RF em FPGA para classificações de sinais mioelétricos, isto torna a comparação direta entre trabalhos não muito adequada. Porém existem diversos estudos em sistemas de reconhecimento de movimentos baseados em sEMG. Com isto pode-se extrair algumas métricas para efeito de comparação.

Em trabalho apresentado por (TOSIN *et al.*, 2017) a mesma base NinaPRO foi utilizada obtendo uma taxa de acerto de 85,67% utilizando 27 características extraídas pelo autor (21 no domínio tempo e 6 no domínio frequência). Este trabalho foi apresentado em um ambiente computacional, que possui maior disponibilidade de processamento em comparação a sistemas embarcados. Outro resultado foi apresentado por (JIA *et al.*, 2021) em que foi proposto um sistema para aquisição e processamento de sinais de sEMG utili-

zando um classificador RF em Python com uma taxa de acurácia de 81%. Estes trabalhos são os que mais se assemelham ao sistema apresentado neste trabalho, embora não sejam sistemas embarcados.

Resultado semelhante foi apresentado por (RAZI *et al.*, 2022) em que foi embarcado um classificador RF para processamento de sinais iEEG em uma FPGA Cyclone V da Altera. Foram utilizadas 3 características no domínio tempo com uma taxa média de acerto de 84% com consumo de 59mW, dados bem próximos aos obtidos neste trabalho e em um *setup* razoavelmente semelhante, porém com outra aplicação.

As taxas de acerto encontradas neste trabalho se aproximam das obtidas nos trabalhos citados anteriormente dadas as suas características individuais. O primeiro trabalho citado apresenta a extração de mais características (27 contra 4) e o segundo trabalho utilizou uma FPGA com ampla disponibilidade de recursos. O protótipo apresentado neste trabalho é capaz de prever movimentos em microssegundos, devido ao fato de o treinamento ocorrer simultaneamente com a classificação. A cada janela deslizante de 150ms o sistema está apto a classificar e treinar um novo movimento, este desempenho está em conformidade com resultados apresentados por (DINH *et al.*, 2023). Estes resultados ainda que preliminares, indicam que é possível a criação de sistemas classificatórios para sinais sEMG embarcados em FPGA.

5 CONCLUSÕES

Este trabalho tem o objetivo de desenvolver um protótipo capaz de adquirir, processar e classificar localmente sinais obtidos através de sEMG de modo *off-line*, ou seja, sem conexões com redes ou aplicativos externos. Algumas escolhas foram tomadas de modo a reduzir os custos do projeto de forma que o impacto técnico fosse o menor possível. Isto limitou a escolha de alguns componentes como o modelo da FPGA utilizada aos invés de utilizar um circuito SoC.

Na entrada do sistema optou-se por um repositório que fosse amplamente conhecido e já discutido de modo a eliminar possíveis fontes de falha ainda desconhecidas oriundas do *dataset*. Com isto, os sinais de eletromiografia referentes a 7 movimentos de 13 indivíduos não amputados foram aplicados a entrada do sistema, para que este extraísse as características pertinentes e a partir de então classificar o movimento com base nestas informações extraídas. Nestes testes, foi obtida uma taxa de acerto de 84% comprovando o funcionamento do classificador.

Quando o protótipo proposto foi submetido a aquisições experimentais de sinais de sEMG, o classificador apresentou uma taxa de acerto de 73,8%. Esta redução pode ser atribuída a não-idealidade do circuito de aquisição e condicionamento visto que os filtros não apresentavam a mesma resposta em frequência e ainda aos efeitos do *crosstalk* entre os canais.

A literatura escassa sobre a aplicação de *Random Forests* em sistemas embarcados aplicados à eletromiografia foi um obstáculo a ser transposto, dificultando a comparação com outros trabalhos na área. Mesmo assim, os resultados dos testes do sistema proposto mostraram sua funcionalidade e este protótipo pode ser direcionado para a próxima fase de desenvolvimento. Portanto, alguns pontos podem ser destacados como tópico para trabalhos futuros.

- Fazer um novo layout do circuito, porém com a FPGA e o sistema de comunicação *on-board* e não mais utilizando soquetes para integração de outros módulos;
- Realizar novas aquisições experimentais e comparar os resultados com os dados

apresentados neste trabalho;

- Com uma nova FPGA, ampliar a quantidade de características extraídas. Talvez incluindo características no domínio frequência;

Seria interessante que o novo sistema seja embarcado em SoC, pois, com esta topologia a lógica de controle pode ser armazenada no microprocessador enquanto que a unidade de processamento pode ficar alocada exclusivamente na FPGA.

REFERÊNCIAS BIBLIOGRÁFICAS

- American Heart Association: Heart disease and stroke statistics-2011 update. *Circulation* (2011).
- ABDOLRAHIM, P. & GAUDET, V. FPGA-Based Architectures for Random Forest Acceleration. **IEEE 65th International Midwest Symposium on Circuits and Systems**. DOI: 10.1109/MWSCAS54063.2022.9859428, 2022.
- ATZORI, M. *et al.* Electromyography data for non-invasive naturally-controlled robotic handprostheses. **Scientific Data**, v. 1, p. 1-13, 2014.
- BARONE, U. & MERLETTI, R. Design of a Portable, Intrinsically Safe Multichannel Acquisition System for High-Resolution, Real-Time Processing HD-sEMG. **IEEE Transactions on Biomedical Engineering**. v. 60, n. 8, 2013.
- BASMAJIAN, J. V. & DE LUCA, C. J. **Muscle alive: their functions revealed by electromyography**. Baltimore: Williams & Wilkins, 1985.
- BOSCHMANN, A. *et al.* Zynq-based acceleration of robust high density myoelectric signal processing. **Science Direct**. v. 123, p. 77-89, 2019.
- BRIOUZA, S. *et al.* Classification of sEMG Biomedical Signals for Upper-Limb Rehabilitation Using the Random Forest Method. **IEEE International Conference on Advanced Systems and Emergent Technologies** DOI: 10.1109/IC_ASET53395.2022.9765871, 2022.
- BUSCHJÄGER, S. & MORIK, K. Decision Tree and Random Forest Implementations for Fast Filtering of Sensor Data. **IEEE Transactions on Circuits and Systems**. v. 65, n. 1, 2018.
- CARRO, Luigi. **Projeto e Prototipação de Sistemas Digitais**. 1ed. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2001.
- CHOI, C. *et al.* Real-time pinch force estimation by surface electromyography using an artificial neural network. **Medical Engineering & Physics**. v. 32, p. 429-436, 2010.
- BREIMAN, L. **Random Forests**. Statistics Department, University of California. Janeiro, 2001.
- CHEN, W. Electromyography-controlled lower extremity exoskeleton to provide wearers

- flexibility in walking. **Biomedical Signal Processing and Control**. v. 79, 2022.
- CRAM, J. F. The History of Surface of Electromyography. **Applied Psychophysiology and Biofeedback**. v. 28, n. 2, 2003.
- CRISWELL, Eleanor. **Cram's Introduction to Surface Electromyography**. 2nd ed. Sudbury, Massachusetts, 2011.
- CUTLER, A. *et al.* **Random Forests**. DOI: 10.1007/978-1-4419-9326-7_5, 2011.
- ENGLEHART, K. *et al.* Classification of the myoelectric signal using time-frequency based representations. **Medical Engineering and Physics**. Amsterdam, v. 21, n. 6/7, p.431-438, 1999.
- DAVID, T. M. *et al.* Future research tendencies for solar energy management using a bibliometric analysis. **Heliyon**. v. 6, n. 7, 2020.
- DINH, T. P. *et al.* A flexible and efficient FPGA-based random forest architecture for IoT applications. Internet of Things. **Elsevier**. v. 22, 2023.
- ELNAWAWY, M. & SAGAHYROON, A. FPGA-Based Network Traffic Classification Using Machine Learning. **IEEE Access**. DOI: 10.1109/ACCESS.2020.3026831, 2020.
- GEETHANJALI, P. & RAY, K. K. EMG based man-machine interaction – A pattern recognition research platform. **Robotics and Autonomous Systems**. v. 62, p. 864-870, 2014.
- GRAHAM, K. *et al.* Estimating the prevalence of limb loss in the United States: 2005 to 2050. **Arch Phys Med Rehabil**. v. 89, p. 422-429, 2008.
- INAME. **O que é Atrofia Muscular Espinhal**. Disponível em: < <https://iname.org.br/a-atrofia-muscular-espinhal/>>. Acesso em 13 de setembro de 2022.
- FINDIK, M. *et al.* Random Forest Classification of Finger Movements using Electromyogram (EMG) Signals. **IEEE**, 2020.
- HAKONEN, M. *et al.* Current state of signal processing myoelectric interfaces related applications. **Biomedical Signal Processing and Control**. v. 18, p. 334-359, 2015.
- JABER, H. A. *et al.* Using the Robust High Density-surface Electromyography Features for Real-Time Hand Gestures Classification. **IOP Conference Series: Materials Science and Engineering**. 2020.
- JAWORSKI, M. *et al.* New Splitting Criteria for Decision Trees in Stationary Data Streams. **IEEE Transactions on Neural Networks and Learning Systems**. v. 29, n. 6, 2018.
- JIA, R. *et al.* Gestures recognition of sEMG signal based on Random Forest. IEEE Conference on Industrial Electronics and Applications. p. 1673-1678. **IEEE**, 2021.
- JINGJUI, A. *et al.* An FPGA Realization of a Random Forest with k-Means Clustering Using a High-Level Synthesis Design. **IEEE Trans. Inf & Syst**. v. d, n. 2, p. 354-362, 2018.

- KACZMAREK, P. *et al.* Put EMG-A Surface Electromyography Hand Gesture Recognition Dataset. **Sensors**. v.19, 3548, 2019.
- KONRAD, Peter. The ABC of EMG. **Noraxon INC.** USA. 2005
- KOUTSOFTIDIS, S. *et al.* Myolink: A 128-Channel, $18\text{nV}/\sqrt{\text{Hz}}$, Embedded Recording System, Optimized for High-Density Surface Electromyography Acquisition. **IEEE Transactions on Biomedical Engineering**. v. 69, n. 11, 2022
- KULAGA, R. & GORGON, M. FPGA Implementation of Decision Trees and Tree Ensembles for Character Recognition In Vivado HLS. **Image Processing & Communication**. v. 19, n. 2, 71-82, 2015.
- KUNDU, B. **Classification and Feature Extraction of Different Hand Movements from the EMG Signal using Machine Learning based Algorithms**. Tese de Mestrado, Univerisdade de Minnesota, EUA, 2021.
- LIU, G. *et al.* A novel energy-motion model for continuous sEMG decoding: from muscle energy to motor pattern. **Journal of Neural Engineering**. v. 18, 2021.
- LIU, X. *et al.* Muscle Compensation Analysis During Motion Based on Muscle Functional Network. **IEEE Sensors Journal**. v. 22, n. 3, 2022.
- MAJOLO, M. **Máquina de Vetores de Suporte Embarcada em Hardware para Classificação de Sinais Mielétricos**. Dissertação de mestrado, Universidade Federal do Rio Grande do Sul, Julho de 2019.
- MASSÓ, N. *et al.* **Surface Electromyography Applications in the Sport**. **Apunts: Medicina del Sport**. v. 45, n. 165, 121-130, 2010.
- MEENA, C. **EMG Feature Extraction and Classification Implementation on FPGA**. Dissertação de mestrado, Malaviya National Institute of Technology, Julho de 2019.
- MENDES, J. *et al.* Circuit Design of Amplification and Filtration for Surface Electromyography Data Acquisition. **IEEE Latin America Transactions**. v. 13, n. 10, 2015.
- MERLETTI, R. & PARKER, P. A. **Electromyography: Physiology, Engineering and Noninvasive Applications**. New Jersey: IEEE PRESS, 2004.
- MOSTAFA, S. *et al.* Design of sEMG-based clench force estimator in FPGA using artificial neural networks. **Neural Computing and Applications**. v. 32, p. 15813-15823, 2020.
- NAM, S. *et al.* Development of Artificial Inteligence to Support Needle Electromyography Diagnostic Analysis. **Healthcare Informatics Research**. v. 25, n. 2, p. 131-138, 2019.
- NILSON, J. & RIEDEL, S. **Circuitos Elétricos** 8ed. São Paulo: Pearson Prentice Hall, 2009.
- NOUGAROU, F. *et al.* Pattern recognition based on HD-sEMG spatial features extraction foran efficient proportional control of a robotic arm. **Biomedical Signal Processing and**

Control. v. 53, p. 101550 2019.

POZZO, M. *et al.* Electromyography: Detection, Processing, and Applications. In: MORE, J.; ZOURIDAKIS, G. (Eds.). . **Biomedical Technology and Devices Handbook.** New York: CRC Press, 2004.p. 70?135.

REAZ, M. B. I. *et al.* Techniques of EMG signal analysis: detection, processing, classification and applications. **Biological Procedures Online.** v. 8, n.1, p. 11-35, 2006.

ROKACH, L. & MAIMON, O. **Data Mining With Decision Trees.** World Scientific, v.81, 2nd ed., Israel, 2015.

SHARMA, S *et al.* Techniques for Feature Extraction from EMG Signal. **International Journal of Advanced Research in Computer Science and Software Engineering.** v. 2, 2012.

SHI, X. *et al.* A new sEMG signal feature extraction method based on S transform. **IEEE International Conference on Real-time Computing and Robotics.** DOI: 978-1-6654-3678-6/21/\$31.00, 2021.

SONG, W. *et al.* Design of a Flexible Wearable Smart sEMG Recorder Integrated Gradient Boosting Decision Tree Based Hand Gesture Recognition. **IEEE Transactions on Biomedical Circuits and Systems.** v. 13, n. 6, 2019.

SONMEZOCAK, Temel; KURT, Serkan. Detection of EMG Signals by Neural Networks Using Autoregression and Wavelet Entropy for Bruxism Diagnosis. **Eletronika Ir Elektrotechnika.** V. 27, n. 2, 2021.

SU, R. *et al.* Random Forest-Based Recognition of Isolated Sign Language Subwords Using Data from Accelerometers and Surface Electromyographic Sensors. **Sensors.** v. 16, n. 100, 2016.

SUN, J. *et al.* Application of Surface Electromyography in Exercise Fatigue: A Review. **Frontiers in Systems Neuroscience.** v. 16, 2022.

TORTORA, G. J. & DERRICKSON, B. **Corpo Humano: Fundamentos de Anatomia e Fisiologia.** 10ed. Porto Alegre: Artmed, 2017.

TOSIN, M. C. *et al.* SEMG feature selection and classification using SVM-RFE. In: Annual International Conference Of The IEEE Engineering In Medicine and Biology Society, 39, 2017. **Proceedings.** New York, IEEE, 2017, p. 390-393.

VAN ESSEN, B. *et al.* Accelerating a random forest classifier: multi-core, GP-GPU, or FPGA? **IEEE 20th International Symposium on Field Programmable Custom Computing Machines.** DOI: 10.1109/FCCM.2012.47, 2012.

VENUTO, D. D. & MEZZINA, G. Field Programmable Gate Array-Embedded Platform for Dynamic Muscle Fiber Conduction Velocity Monitoring. **Sensors.** v. 19, n. 4954, 2019.

WHÖRLE, H. *et al.* A Hybrid FPGA-Based System for EEG- and EMG-Based Online

Movement Prediction. **Sensors**. v. 17, n. 1552, 2017. DOI:10.3390/s17071552.

XUE, Y. *et al.* SEMG-Based Human In-Hand Motion Recognition Using Nonlinear Time Series Analysis and Random Forest. **IEEE Access**. v. 7, 2019.

ZHU, M. *et al.* An Efficient FPGA-based Accelerator for Deep Forest. **IEEE International Symposium on Circuits and Systems**., 2022. DOI: 978-1-6654-8485-5/22/\$31.00

ZOU, T. *et al.* Adapting Random Forest Classifier Based on Single and Multiple Features for Surface Electromyography Signal Recognition. **ResearchGate**. DOI: 10.1109/CISP-BMEI48845.2019.8965719, 2019.

APÊNDICE A

A.1 Layout da placa




Figura 51: Layout da face bottom da placa.

Fonte: Autor.

A.2 Matriz de confusão dos demais usuários da base NinaPRO

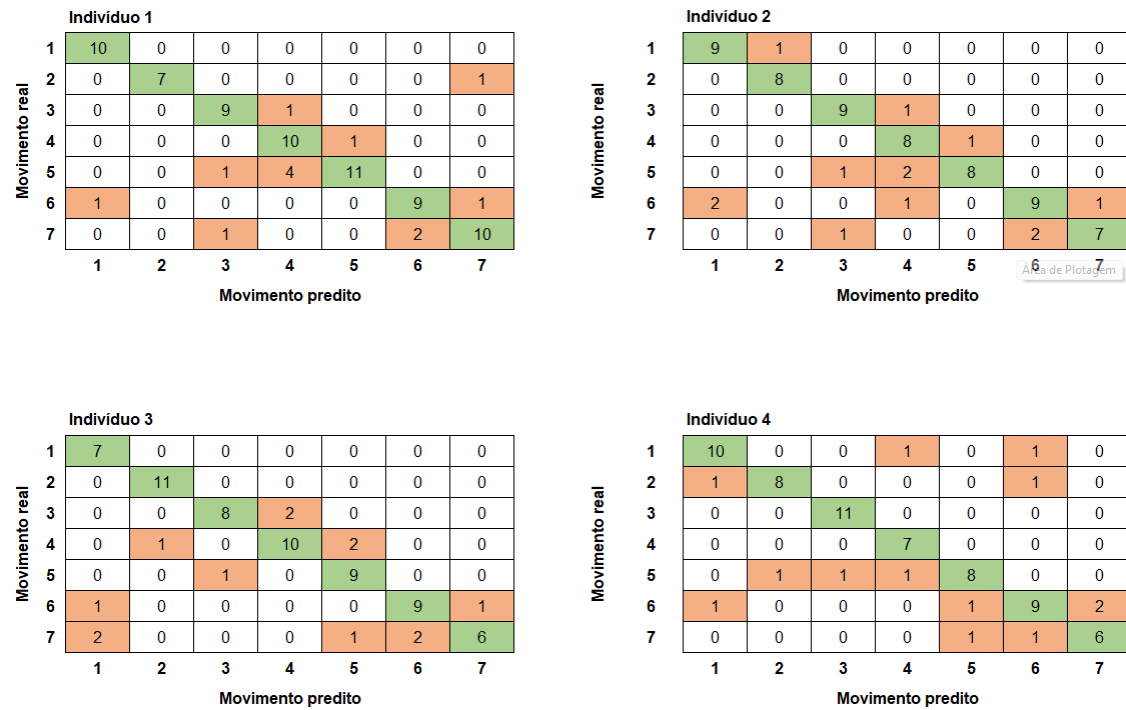


Figura 52: Matriz de confusão dos usuários 1 a 4 da base NinaPRO.

Fonte: Autor.

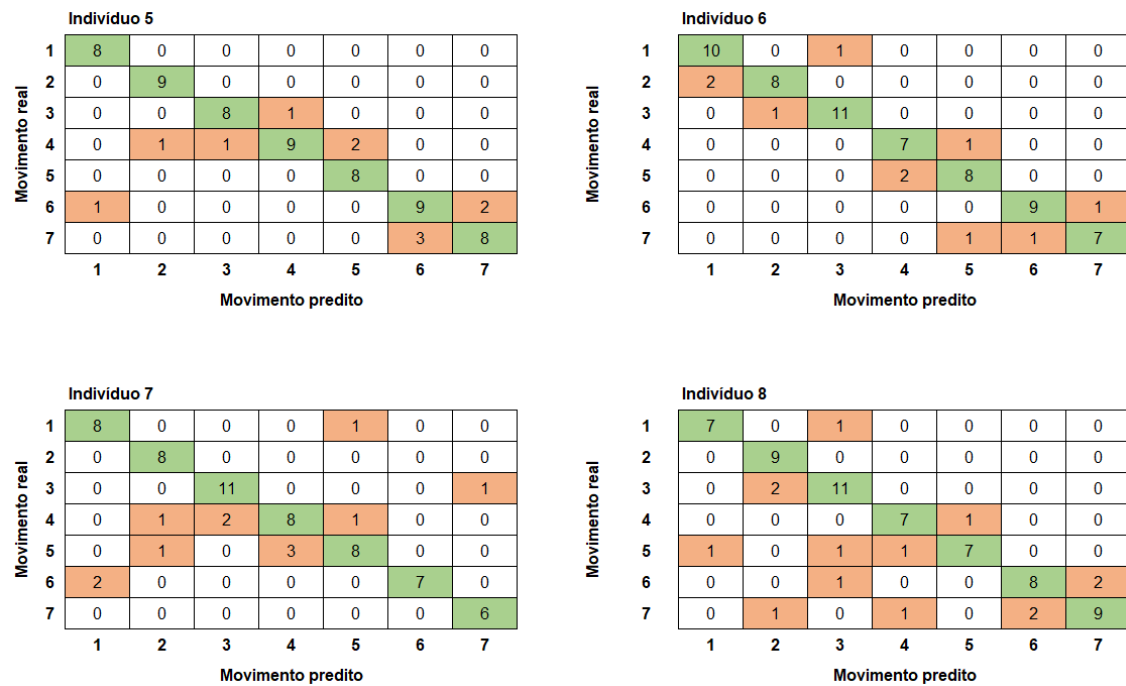


Figura 53: Matriz de confusão dos usuários 5 a 8 da base NinaPRO.

Fonte: Autor.

1	6	0	0	1	0	1	0
2	1	8	0	0	1	0	0
3	0	0	7	0	0	1	0
4	0	0	1	9	1	0	1
5	0	1	0	0	8	0	0
6	0	0	0	0	0	9	0
7	0	1	0	1	0	1	7
	1	2	3	4	5	6	7

Movimento real

Movimento predito

1	7	1	1	0	0	0	0
2	0	9	0	0	0	1	1
3	0	0	7	0	0	0	0
4	0	0	0	7	2	0	0
5	0	0	0	1	8	0	0
6	0	0	0	1	0	8	0
7	1	1	0	1	0	0	7
	1	2	3	4	5	6	7

Movimento real

Movimento predito

1	9	0	0	0	0	0	0
2	0	9	0	0	1	0	0
3	1	0	7	0	0	0	0
4	0	0	0	7	0	1	0
5	0	2	0	2	8	0	0
6	0	0	0	1	0	9	1
7	0	0	2	0	0	1	7
	1	2	3	4	5	6	7

Movimento real

Movimento predito

Figura 54: Matriz de confusão dos usuários 9 a 12 da base NinaPRO.

Fonte: Autor.

A.3 Varredura em frequência dos demais canais

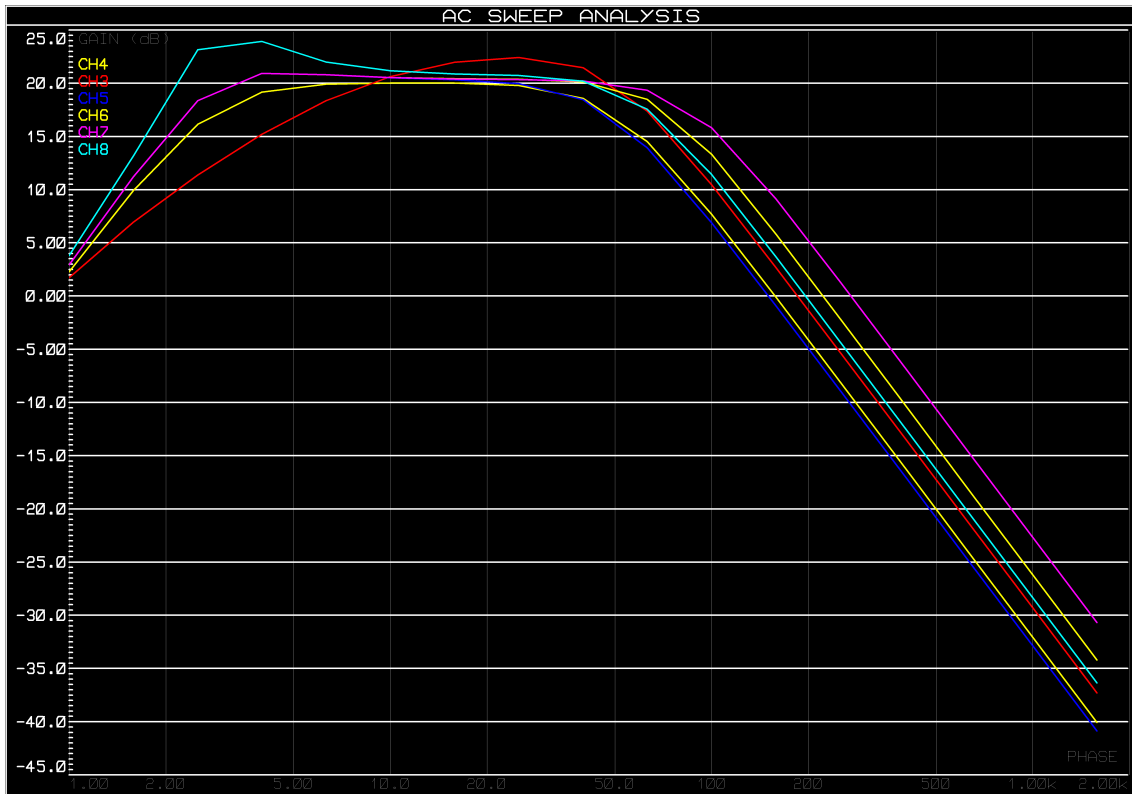


Figura 55: Validação dos filtros dos canais 3 ao 8.

Fonte: Autor.